

Universidade Federal do Espírito Santo – UFES

Centro Tecnológico

Programa de Pós-Graduação em Engenharia Elétrica

WELLINGTON GASPERACCO

**Rede Neural Artificial Aplicada ao Rastreamento de Pontos
de Máxima Potência de Painéis Fotovoltaicos com
Sombreamento Parcial**

**Vitória
2018**

WELLINGTON GASPERACCO

**Rede Neural Artificial Aplicada ao Rastreamento de Pontos
de Máxima Potência de Painéis Fotovoltaicos com
Sombreamento Parcial**

Dissertação apresentada ao Programa de
Pós-Graduação em Engenharia Elétrica
do Centro Tecnológico da Universidade
Federal do Espírito Santo como requisito
parcial para obtenção do título de Mestre
em Engenharia Elétrica

Orientador: Prof. Dr. Domingos Sávio
Lyrio Simonetti

Co-orientadora: Profa. Dra. Jussara
Farias Fardin

**VITÓRIA
2018**

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)
Sandra Mara Borges Campos – CRB-6 ES-000593/O

G249r Gasperacco, Wellington, 1986-
Rede neural artificial aplicada ao rastreamento de pontos de
máxima potência de painéis fotovoltaicos com sombreamento
parcial / Wellington Gasperacco. – 2018.
88 f. : il.

Orientador: Domingos Sávio Lyrio Simonetti.
Coorientador: Jussara Farias Fardin.
Dissertação (Mestrado em Engenharia Elétrica) –
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Energia solar. 2. Sombras e sombreios. 3. Redes neurais
(Computação). 4. Sistemas de energia fotovoltaica. 5. Controlador
de carga MPPT. I. Simonetti, Domingos Sávio Lyrio. II. Fardin,
Jussara Farias. III. Universidade Federal do Espírito Santo.
Centro Tecnológico. IV. Título.

CDU: 621.3

WELLINGTON GASPERACCO

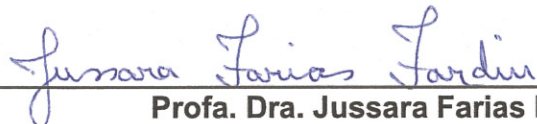
**REDE NEURAL ARTIFICIAL APLICADA AO
RASTREAMENTO DE PONTOS DE MÁXIMA POTÊNCIA DE
PAINÉIS FOTOVOLTAICOS COM SOMBREAMENTO
PARCIAL**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

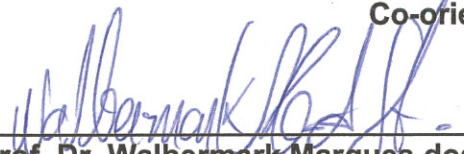
Aprovada em 21/02/2018 por:



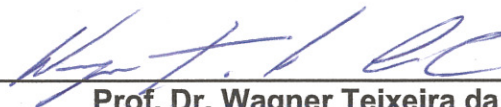
Prof. Dr. Domingos Sávio Lyrio Simonetti
Universidade Federal do Espírito Santo
Orientador



Profa. Dra. Jussara Farias Fardin
Universidade Federal do Espírito Santo
Co-orientadora



Prof. Dr. Walbermark Marques dos Santos
Universidade Federal do Espírito Santo



Prof. Dr. Wagner Teixeira da Costa
Instituto Federal do Espírito Santo

Universidade Federal do Espírito Santo
Vitória, Fevereiro de 2018

O que sabemos é uma gota e o que ignoramos é um oceano.

(Isaac Newton)

Agradecimentos

Agradeço primeiramente a Deus por propiciar muitas bênçãos em minha vida, aos meus orientadores professor Domingos e professora Jussara pela oportunidade e pelo suporte durante todo o período do curso, ao programa de pós graduação em engenharia elétrica da Universidade Federal do Espírito Santo, agradecimentos também à Capes pela bolsa de mestrado, aos meus colegas do LEPAC pelas auxílios, aos colegas de trabalho do Ifes – Campus Linhares, à minha família pelo apoio incondicional e aos amigos de Vitória e de Colatina.

Resumo

Nos painéis fotovoltaicos, o ponto de potência máxima depende dos níveis de irradiância solar e temperatura. Determinar o valor de máxima potência é uma tarefa complexa, em especial, quando a irradiância não é uniforme, isto é, quando há sombreamento parcial no painel. Este trabalho aplica uma rede neural artificial (RNA) para identificação do ponto de operação com potência máxima em painéis fotovoltaicos em diferentes condições de sombreamento, seja ele total ou parcial. Utiliza-se como parâmetros de entrada no treinamento e teste da RNA a irradiância solar (dada em W / m^2), temperatura ($^{\circ}C$) e a tensão de circuito aberto do painel (V). A informação buscada na saída da rede neural artificial é o valor de tensão (V) a impor para operar em máxima potência. No estudo, por simulação, foi desenvolvida uma RNA do tipo MLP (Perceptron de Múltiplas Camadas) com duas camadas ocultas de 13 neurônios cada. Foram utilizadas 554 amostras de parâmetros para o treinamento da RNA, e 92 para comprovação, gerados a partir de um modelo desenvolvido no software Matlab/Simulink®. Os resultados dos testes retornaram uma taxa de erro em torno de 6%, mostrando que a rede neural artificial com a abordagem proposta pode ser uma solução eficiente para detecção do ponto de máxima potência em diversas situações de sombreamento.

Palavras-chave: Energia Solar, MPPT, Redes Neurais Artificiais.

Abstract

In photovoltaic panels, the maximum power point depends on the levels of solar irradiance and temperature. Determining the maximum power value is a complex task, especially when the irradiance is not uniform, i.e. when there is partial shading on the panel. This work applies an artificial neural network (ANN) to identify the point of operation with maximum power in photovoltaic panels under different conditions of shading (solar radiation), total or partial. The solar irradiance (given in W / m^2), temperature ($^{\circ} C$) and the open circuit voltage of the panel (V) are used as inputs for training and RNA testing. The information sought at the output of the artificial neural network is the voltage value (V) to be imposed to operate at maximum power. In the study, by simulation, an MLP (Multiple Layer Perceptron) type RNA was developed with two hidden layers of 13 neurons each. For ANN training were used 554 samples of parameters, and 92 for verification, generated from a model developed in Matlab / Simulink® software. The results of the tests returned an error rate around 6%, showing that the artificial neural network with the proposed approach can be an efficient solution to detect the maximum power point in several shadowing situations.

Keywords: Artificial Neural Network, Solar Energy, MPPT, partial shading.

Lista de Ilustrações

Figura 1 - Ilustração do Efeito Fotovoltaico.....	22
Figura 2 - Módulo Fotovoltaico com 36 células ligadas em série.....	23
Figura 3 – Ligação em Série das Células Fotovoltaicas.....	23
Figura 4 – Células, Módulos e Painéis.....	24
Figura 5 – Modelo elétrico Ideal de uma célula Fotovoltaica.....	24
Figura 6 – Modelo Real de uma célula Fotovoltaica.....	25
Figura 7 – Curva Característica de uma Célula Fotovoltaica	26
Figura 8 - Comportamento da Potência em Função da Tensão.	27
Figura 9 - Variação da curva I-V do módulo fotovoltaico usado na simulação com diferentes temperaturas.	28
Figura 10 - Variação da curva I-V do módulo fotovoltaico utilizado na simulação com diferentes irradiações.	29
Figura 11 - Ligação de diodos de <i>by-pass</i> em módulos fotovoltaicos	31
Figura 12 - Curva característica com sombreamento parcial.	31
Figura 13 - Curva característica de um painel fotovoltaico com indicação do ponto de máxima potência.	33
Figura 14 - Técnica Perturba e Observa.	36
Figura 15 - Fluxograma Básico Técnica Perturba e Observa.....	37
Figura 16 – Trajetória do ponto de máxima potência com a variação da irradiância.....	39
Figura 17- Fluxograma Básica Técnica Condutância Incremental.	40
Figura 18 - Neurônio biológico e neurônio artificial.	44
Figura 19 - Rede Neural Artificial Multilayer Perceptron.....	46
Figura 20 - Funções de Ativação.....	47
Figura 21 - Representação da polarização e da variância em função da complexidade da RNA.....	50
Figura 22 - Utilização da RNA para estimação do ponto de máxima potência.....	57
Figura 23 - Modelo utilizado para geração das curvas características.....	59
Figura 24 - Curvas Características I x V e P x V.....	60
Figura 25 - Sem Sombreamento, $G = 400 \text{ W/m}^2$ e $T = 35 \text{ }^\circ\text{C}$	61
Figura 26 - Sombreamento em 1/3 do painel, $G_{\text{max}} = 800 \text{ W/m}^2$, $G_{\text{min}} = 400 \text{ W/m}^2$ e $T = 15 \text{ }^\circ\text{C}$	62
Figura 27 - Configuração da RNA utilizada.	67

Figura 28 - Comparação dos resultados da RNA com os resultados esperados e Regularização Bayesiana.....	70
Figura 29 - Erro individual apresentado pela RNA com Regularização Bayesiana ...	70
Figura 30 - Comparação dos resultados da RNA com treinamento Levenberg-Marquardt e os resultados esperados.	72
Figura 31- Erro Individual das amostras apresentada pela RNA utilizando o método Levenberg-Marquardt.....	72
Figura 32 - Comparação dos resultados da RNA com os resultados esperados Regularização Bayesiana.....	73
Figura 33 - Erro individual apresentado pela RNA Regularização Bayesiana.....	74
Figura 34 - Comparação dos resultados da RNA com os resultados esperados Levenberg-Marquardt.....	75
Figura 35 - Erro Individual das amostras apresentada pela RNA utilizando o método Levenberg-Marquardt.....	75
Figura 36 - Comparação em linhas entre a potência máxima conhecida e a potência obtida a partir do valor de tensão do processamento da RNA.	77
Figura 37 - Comparação em colunas entre a potência máxima conhecida e a potência obtida a partir do valor de tensão do processamento da RNA.....	77
Figura 38 - Mínimo local próximo ao Máximo Global.	78
Figura 39- Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).	79
Figura 40 – Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).	79
Figura 41 – Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).	80
Figura 42 – Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).	80

Lista de Tabelas

Tabela 3.1 - Dados do módulo fotovoltaico utilizado.	58
Tabela 3.2 - Dados para simulação do painel.....	59
Tabela 3.3 – Parcial de dados extraídos do modelo utilizado.....	63
Tabela 3.4 – Parcial de dados extraídos do modelo utilizado.....	64
Tabela 3.5 – Parcial de dados reais e dados normalizados.	65

Lista de Símbolos

W	Watt
m ²	metro quadrado
V	Volt
A	Ampère
kWh	kilo Watt hora
K	Kelvin
kg	kilograma
s	segundo
Hz	Hertz
J	Joule
Ω	Ohm
°C	graus Celsius

Lista de Abreviaturas

RNA	Redes Neurais Artificiais
MLP	Perceptron de Múltiplas camadas
MPPT	Rastreamento dos Pontos de máxima Potência
MPP	Ponto de máxima Potência (maximum power point)
V_{mp}	Tensão de Máxima Potência
I_{mp}	Corrente de Máxima Potência
V_{oc}	Tensão de Circuito Aberto
I_{sc}	Corrente de Curto Circuito
I_m	Corrente Máxima
STC	Standart Test Condition

Sumário

1. INTRODUÇÃO	16
1.1 Justificativa.....	17
1.2 Estado da Arte.....	17
1.3 Objetivo	18
1.4 Motivação	19
1.5 Conteúdo do Trabalho.....	19
2. REVISÃO BIBLIOGRÁFICA.....	21
2.1 Efeito Fotovoltaico e a Célula fotovoltaica.....	21
2.2 Influência da Temperatura e da Irradiância.	28
2.2.1 Temperatura.....	28
2.2.2 Irradiância.....	29
2.3 Efeitos do Sombreamento parcial nos painéis fotovoltaicos.	29
2.4 Pontos de Máxima Potência em Painéis Fotovoltaicos	32
2.4.1 Técnicas Convencionais para o Rastreamento de Pontos de Máxima Potência.....	33
2.4.1.1 Técnica da Tensão de Circuito Aberto	33
2.4.1.2 Técnica Perturba e Observa	35
2.4.1.3 Técnica Condutância Incremental.....	37
2.4.2 Técnicas para rastreamento de pontos de máxima potência de painéis fotovoltaicos com sombreamento	40
2.4.2.1 Técnica de Chen et al. (2014).....	41
2.4.2.2 Técnica de Boztepe et. al (2014)	42
2.5 Redes Neurais Artificiais (RNA)	43
2.5.1 Redes Perceptrons de Múltiplas Camadas (MultiLayer).....	45
2.5.2 – Treinamento da Rede Neural Artificial (RNA)	48
2.5.3 – Algoritmo BackPropagation.....	52
2.5.4 – A Regularização Bayesiana	53
2.5.5 – Método de Treinamento Levenberg-Maquardt.....	54
2.5.6 – Teste da RNA.....	55
3. METODOLOGIA PROPOSTA	56
3.1 Aplicação de RNA ao MPPT de Arranjos Fotovoltaicos	56
3.2 Montagem da Base de Dados para o treinamento e teste da RNA.....	57
3.3 Normalização da base de dados para treinamento e teste da RNA.....	64
3.4 Configuração da Rede Neural Artificial.....	65

4. RESULTADOS	69
5. CONCLUSÕES	81
REFERÊNCIAS.....	83

1. INTRODUÇÃO

O desenvolvimento da sociedade responde de forma direta no aumento da demanda por energia elétrica, e a preocupação crescente com as questões relativas ao aquecimento global e a redução da oferta por combustíveis fósseis tem de certa forma impulsionado o desenvolvimento de fontes de energia renováveis (KWON et al, 2006). As energias não renováveis são hoje a principal fonte de energia disponível, em 2012 cerca de 80% da energia no mundo era proveniente de fontes de energia não renováveis (FURTADO, 2016). Em alguns países a geração de eletricidade é a atividade econômica com maior emissão de CO₂ na atmosfera, contribuindo de forma significativa para o aquecimento global (IEA, 2015). Visando tornar a matriz energética mais limpa, as energias renováveis assumem um papel importante neste cenário, tendo como principal ator a energia solar. A energia solar é responsável por praticamente todas as formas de energia conhecidas, como a biomassa, hidráulica, eólica, fotovoltaica e inclusive os combustíveis fósseis. Apesar de todas as vantagens apresentadas pela geração de energia através do uso dos módulos fotovoltaicos, a eficiência da conversão de energia é atualmente baixa, porém o custo inicial para a implantação vem diminuindo, o que acarreta um aumento significativo no número de instalações fotovoltaicas nos últimos anos, somente em 2016 houve um crescimento de 359,1% na potência instalada no Brasil (ANEEL, 2017). A expansão da tecnologia fotovoltaica tem crescido praticamente de forma exponencial desde a década de 1970. Pode-se atribuir este crescimento a dois aspectos distintos: o primeiro se refere à melhora dos materiais empregados na fabricação das células fotovoltaicas, e um segundo aspecto se refere à busca por fontes renováveis de energia que respeitem legislações vigentes, levando em consideração o apelo ecológico e a dificuldade na obtenção de licenças dos órgãos ambientais para construções de grandes empreendimentos para a geração de energia (FARIA, 2014). Considerando a baixa eficiência presente na geração fotovoltaica torna-se necessário a utilização de técnicas que garantam a operação do painel em seu ponto de máxima potência instantâneo, técnicas essas denominadas MPPT (*Maximum Power Point Tracking*) (COELHO, 2009). É necessário frisar que, instantaneamente, há apenas um ponto de máxima potência, e este varia de acordo com as condições climáticas de irradiância e temperatura.

Existem várias técnicas para o rastreamento dos pontos de máxima potência, algumas delas utilizam a curva característica do painel fotovoltaico (Tensão *versus* Corrente), outras se baseiam no modelo matemático do painel e outras técnicas são determinadas a partir do uso de ferramentas de inteligência artificial. Cada uma dessas técnicas reage de uma maneira diante de um cenário de sombreamento parcial, ou seja, quando o valor da irradiância é diferente em partes distintas do painel. O sombreamento parcial causa, além de perdas relevantes na capacidade de geração do arranjo em relação à situação não sombreada, a alteração das características de relação entre tensão e corrente dos arranjos. Esta alteração dificulta a tarefa de manter o ponto de operação de tensão e corrente do arranjo fotovoltaico na condição em que é extraída a maior potência elétrica possível em cada situação de irradiância incidente e de temperatura (FURTADO, 2016).

1.1 Justificativa

A utilização de painéis fotovoltaicos para a geração de energia elétrica traz algumas vantagens. O sol é uma fonte inesgotável de energia, o custo de operação e manutenção são relativamente baixo, é uma energia limpa entre outras vantagens, porém, a sua principal desvantagem é a questão do rendimento, daí a necessidade de se extrair a máxima potência dos painéis, e uma das formas de se extrair essa máxima potência é através do uso de técnicas de rastreamento dos pontos de máxima potência.

1.2 Estado da Arte

Alguns trabalhos apresentados na literatura abordam o rastreamento dos pontos de máxima potência dos painéis fotovoltaicos utilizando ferramentas de inteligência artificial, como por exemplo, redes neurais artificiais e lógica nebulosa (*Fuzzy*).

Em Chuco (2007) é apresentada uma proposta de otimização da potência de operação em sistema fotovoltaico isolado usando técnicas de inteligência artificial, foi implementado um sistema em lógica *Fuzzy* para estimar a tensão ótima a partir dos dados de temperatura e irradiância e para manter a operação no ponto de máxima potência foi utilizado um controlador utilizando redes neurais artificiais que atua sobre o conversor CC-CC. A técnica apresentada se mostrou eficiente para os padrões apresentados, porém não foi levada em conta a questão do sombreamento

parcial.

Em Bastos (2012) é apresentada uma rede neural artificial aplicada na busca do ponto de máxima potência em painéis fotovoltaicos, o intuito dessa abordagem é tornar a busca pelo ponto de máxima potência mais rápida além de reduzir as oscilações criadas pelos métodos convencionais (no caso deste trabalho o método Perturba & Observa), levando em consideração as condições de temperatura e irradiância no qual o painel é exposto, determinando assim os pontos de máxima potência em cada ponto, os resultados foram satisfatórios na maioria dos testes, porém a questão do sombreamento parcial também não foi abordada neste trabalho.

Em Faria (2014), é apresentado um estudo do sombreamento parcial em módulos fotovoltaicos através da resistência série e das redes neurais artificiais, o objetivo é estudar o comportamento dos módulos fotovoltaicos mediante situações de sombreamento, que causa impacto em praticamente todos os parâmetros elétricos do painel, foi feito um estudo da resistência série dos módulos nas condições de sombreamento possibilitando uma possível identificação do estado de sombreamento a partir do monitoramento da resistência série. Este trabalho também aborda a utilização de redes neurais artificiais para identificar os parâmetros do módulo fotovoltaico dentro das diversas condições de sombreamento parcial proposta, podendo ser usada como complemento a sistemas de monitoramento e rastreamento de pontos de máxima potência em painéis fotovoltaicos.

Em Furtado (2016) é exposto uma série de técnicas atuais de rastreamento de pontos de máxima potência quando o painel está sob influência do sombreamento parcial, como a técnica de Chen *et al.* (2014), técnica de Boztepe *et al.* (2014) e técnica do triângulo do MPPT. São técnicas que não utilizam de ferramentas da inteligência artificial, porém apresentam bons resultados na busca pelos pontos de máxima potência.

A proposta desta dissertação é apresentar uma rede neural artificial capaz de rastrear os pontos de máxima potência de um painel fotovoltaico sob sombreamento parcial baseado em dados de temperatura e irradiância.

1.3 Objetivo

Esta dissertação de mestrado apresenta uma revisão bibliográfica sobre energia solar fotovoltaica, técnicas de rastreamento de pontos de máxima potência em painéis fotovoltaicos e redes neurais artificiais, além de aplicar redes neurais

artificiais para o rastreamento dos pontos de máxima potência através de um modelo de simulação. Os objetivos específicos estão listados abaixo:

- Levantamento na literatura dos assuntos relacionado à energia solar fotovoltaica;
- Levantamento de algumas técnicas utilizadas no rastreamento dos pontos de máxima potência de painéis fotovoltaicos;
- Desenvolvimento de um modelo de simulação para painéis fotovoltaicos sombreados parcialmente utilizando o *software* Matlab®*Simulink*;
- Desenvolvimento de uma rede neural artificial através dos dados obtidos na simulação do painel com o intuito de determinar os pontos de máxima potência.

1.4 Motivação

Uma vez vista a importância dos painéis fotovoltaicos de operar nos pontos de máxima potência, foi considerada a utilização de um método para a busca desses pontos em painéis fotovoltaicos com sombreamento parcial. O método apresentado neste trabalho faz uso de Redes Neurais Artificiais. Uma vez conhecido o comportamento dos pontos de máxima potência, isto é, conhecer como ocorre a variação desses pontos quando colocados em condições climáticas diferentes, foi possível desenvolver uma rede neural artificial capaz de encontrar esses pontos.

1.5 Conteúdo do Trabalho

Neste trabalho o principal objetivo foi o estudo do comportamento das características elétricas dos painéis fotovoltaicos quando estes estão submetidos à diferentes condições de temperatura e irradiância e apresentar uma técnica para rastreamento dos pontos de máxima potência do painel utilizando Redes Neurais Artificiais. Foram utilizados para a montagem da base de dados uma plataforma de simulação do *software* MatLab/Simulink®, onde foram colocados em série dois

módulos fotovoltaicos Canadian Solar CS6P-250M-EA, de 250W de potência pico cada, gerando uma potência máxima de saída de 500W para as condições nominais de teste.

No capítulo 2 é feita uma revisão bibliográfica detalhada sobre os principais assuntos desenvolvidos durante este trabalho, informações a respeito do efeito fotovoltaico sobre as células fotovoltaicas, sobre a influência das condições climáticas, efeito do sombreamento parcial e total. Também é apresentada uma contextualização sobre as redes neurais artificiais e sobre pontos de máxima potência em painéis fotovoltaicos.

No capítulo 3 é apresentada a metodologia proposta. Se explica como Redes Neurais Artificiais podem ser aplicadas para o rastreamento de pontos de máxima potência, como foi feita a montagem da base de dados para o treinamento e teste da RNA, como foi feita a formatação dos dados para obter um melhor resultado de resposta da RNA, e a configuração da RNA utilizada.

No capítulo 4 são apresentados os resultados obtidos e as discussões desses resultados. Faz-se uma comparação com os dados esperados, uma vez que estes são conhecidos, e também são apresentados e discutidos os erros individuais. Por fim uma comparação dos valores de potência obtidos quando a referência para o conversor estático, que controla a tensão de saídas do painel, são os dados provenientes do processamento da RNA e os dados de Potência máxima conhecidos.

No capítulo 5 encontram-se as devidas conclusões, além de sugestões para trabalhos futuros. Apresenta-se também a produção científica gerada a partir deste trabalho.

2. REVISÃO BIBLIOGRÁFICA

2.1 Efeito Fotovoltaico e a Célula fotovoltaica

O efeito fotovoltaico foi percebido a primeira vez por Alexandre-Edmond Becquerel em 1839, que constatou a presença de uma diferença de potencial nos terminais de um semicondutor quando exposto a luz (CRESESB, 2006). Na origem deste fenômeno está o efeito fotoelétrico (MOÇAMBIQUE, 2012).

O efeito fotoelétrico foi comprovado por Albert Einstein em 1905, quando este propôs que a radiação eletromagnética é quantizada. A luz solar é uma radiação eletromagnética e se propaga transportando energia em forma de fótons (HALLIDAY et al, 2011).

A radiação solar é proveniente da fusão nuclear dos átomos de hidrogênio no núcleo do sol, que ocorre a altíssimas temperaturas emanando calor e luz em direção ao espaço. A radiação emitida pelo sol vista da terra equivale à emitida por um corpo negro (condutor e receptor ideal da radiação eletromagnética) de 6000K. A equação 2.1, conhecida como equação de Planck, descreve a distribuição do comprimento de onda da radiação do corpo negro, estabelecendo relações entre frequência, temperatura e brilho espectral (MOÇAMBIQUE, 2012).

$$E = hf \quad (2.1)$$

Onde:

E = Energia [J]

h = Constante de Planck = $6,62607004 \times 10^{-34}$ [J.s]

f = Frequência [Hz]


No entanto, antes de atingir o solo, a intensidade, a distribuição espectral e angular da radiação solar é afetada pelos efeitos da absorção e espalhamento que ocorrem na atmosfera terrestre, fazendo com que nem toda radiação que atinge o planeta chegue à superfície, sendo parte dela refletida (CRESESB, 2006).

Já o efeito fotoelétrico ocorre quando um feixe de luz com determinada frequência incide sobre uma superfície metálica provocando a ejeção de elétrons da superfície.

Uma célula fotoelétrica é composta basicamente por duas camadas de material semiconductor de características opostas e levemente dopadas de forma a apresentar elétrons fracamente ligados ao núcleo. Esta camada, que no módulo é a que fica submetida à incidência de luz, é do tipo N. A outra camada é do tipo P, dopada de forma a apresentar carência de elétrons. A falta de elétron é denominada buraco ou lacuna, consideradas cargas positivas livres. Por estarem justapostas, na junção forma-se um campo elétrico devido aos elétrons livres da camada tipo N ocupar os vazios da estrutura tipo P, fenômeno que ocorre até que o campo elétrico produzido forma uma barreira capaz de barrar os elétrons livres remanescentes no lado N. Na fronteira aparece então uma diferença de potencial, positiva no lado N.

Quando a luz incide sobre a camada N, os fótons fornecem energia aos elétrons livres restantes da camada (a maioria). Havendo um caminho fechado, ocorre a circulação de elétrons externamente de N para P, gerando uma corrente elétrica conforme a Figura 1.


Figura 1 - Ilustração do Efeito Fotovoltaico.



A célula fotovoltaica é a responsável por transformar a energia luminosa solar em corrente elétrica. Contudo, a potência máxima de uma célula fotovoltaica gira em torno de 4W, e fornece baixo nível de tensão. Portanto, para uma maior produção de energia é necessário a associação de várias células, através de ligações série e paralelo, formando assim os módulos fotovoltaicos. Um modelo comercial comum no

mercado é o módulo de 36 células conectadas em série para ter-se uma saída próxima a 12V como na Figura 2 (CARNEIRO, 2010).


Figura 2 - Módulo Fotovoltaico com 36 células ligadas em série.



Fonte: Carneiro (2010).

Também são comercializados módulos com 60 e 72 células com potências entre 200 e 250W. A ligação em série é feita soldando o contato superior, ou seja, o polo negativo de cada célula ao contato inferior que seria o polo positivo da próxima célula, conforme a Figura 3 (CARNEIRO, 2010).

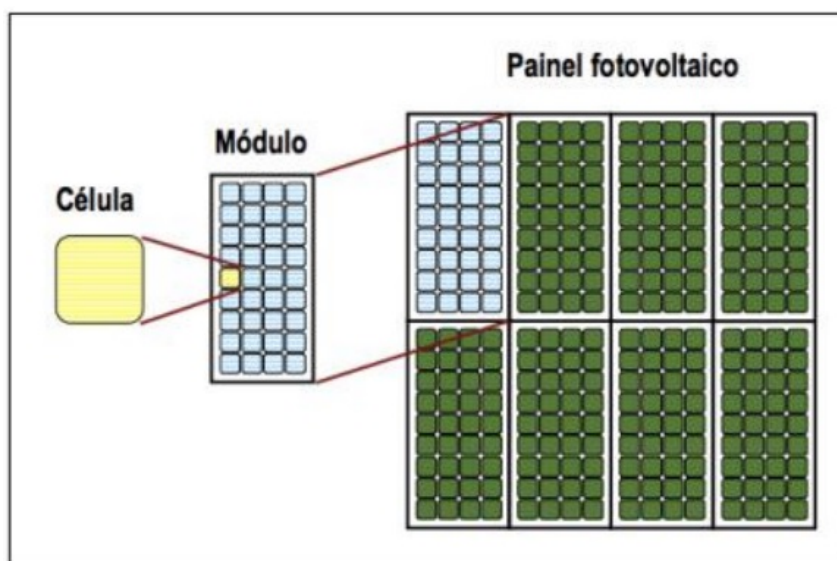
Figura 3 – Ligação em Série das Células Fotovoltaicas.



Fonte: Carneiro (2010).

Os módulos fotovoltaicos por sua vez podem ser conectados a outros módulos em série ou em paralelo, de acordo com o valor de tensão e corrente desejada para a aplicação, formando os painéis fotovoltaicos. Por fim a conexão de grupos de painéis formam as *strings*, também conhecidos como arranjos fotovoltaicos ou *arrays* (CARNEIRO, 2010), como pode ser visto na Figura 4.


Figura 4 – Células, Módulos e Painéis.



Fonte: Carneiro (2010).

As células fotovoltaicas podem ser estudadas a partir de um modelo elétrico equivalente, como mostra a Figura 5. Tal figura mostra uma fonte de corrente de magnitude I_{ph} , equivalente à intensidade de radiação solar (irradiância) e temperatura do ambiente, além da corrente I_d , do diodo diretamente polarizado que flui internamente na junção $p-n$ do semicondutor em uma determinada temperatura absoluta T , e da tensão nos terminais V (OLIVEIRA et al, 2016).

Figura 5 – Modelo elétrico Ideal de uma célula Fotovoltaica




Fonte: Oliveira (2016).

Como o modelo da célula solar ideal não representa uma boa precisão das

características reais das células solares, é necessário que se acrescente mais alguns parâmetros, a resistência série (R_s) e a resistência paralela (R_p), gerando um modelo elétrico mais real da célula fotovoltaica representado na Figura 6 (RAUSCHENBACH, 1980).

Figura 6 – Modelo Real de uma célula Fotovoltaica



Fonte: Oliveira (2016).

Analisando o modelo real observa-se que a resistência R_p em paralelo com o diodo representa as perdas por correntes de fuga que ocorrem nas extremidades da célula solar, enquanto a resistência R_s , na saída, caracteriza as quedas de tensão na condução de carga entre o material semiconductor e o contato externo (OLIVEIRA et al, 2016). A equação 2.2 descreve o circuito equivalente do modelo com resistência em paralelo.

$$I = I_{ph} \left[\exp \left(\frac{V + IR_s}{n_s \cdot m \cdot V_t} \right) - 1 \right] - \frac{V + IR_s}{R_p} \quad (2.2)$$

Sendo:

V_t = Tensão Térmica;


n_s = número de células em série que constituem o módulo fotovoltaico;

m = fator de idealidade do diodo.

A Figura 7 mostra a forma típica do comportamento da corrente gerada pelo módulo em função da tensão em seus terminais. As resistências R_s e R_p interferem nas inclinações da curva $I \times V$ nas regiões anterior e posterior ao ponto de máxima

potência (MPP).

Figura 7 – Curva Característica de uma Célula Fotovoltaica




Fonte: Adaptado de Oliveira (2016).

Nessas regiões a célula fotovoltaica apresenta características de fonte de corrente ($V < V_{mp}$), fonte de tensão ($V > V_{mp}$) e fonte de potência ($V = V_{mp}$). Alguns pontos destes apresentados merecem destaque (OLIVEIRA et al, 2016):

- i. Corrente de curto circuito ($0, I_{sc}$);
- ii. Ponto de máxima Potência (V_{mp}, I_{mp});
- iii. Tensão de Circuito Aberto ($V_{oc}, 0$).

Complementando a análise das curvas características da célula fotovoltaica, a Figura 8 apresenta um gráfico que representa o comportamento da potência em função da tensão gerada pelas células.

Figura 8 - Comportamento da Potência em Função da Tensão.



Fonte: adaptado Canesin (2010).

A característica $I \times V$ de um módulo é função da temperatura e irradiância incidente na mesma. Uma aproximação para a corrente I_{fv} gerada é dada pela equação 2.3:

$$I_{fv} = (I_{fv,n} + K_1 \Delta T) \frac{G}{G_n} \quad (2.3)$$

Onde G e G_n são as irradiâncias solares de W/m^2 na superfície da célula e o valor nominal da mesma, respectivamente; $\Delta T = (T - T_n)$ é a variação da temperatura em Kelvin, sendo T e T_n as temperaturas atual e sob condição nominal, respectivamente; K_1 é o coeficiente de temperatura em A/K da corrente de curto circuito; e $I_{fv,n}$ é a corrente em ampères gerada pela incidência de luz sobre a célula fotovoltaica nas condições nominais ($T_n = 25^\circ C$ e $G_n = 1000 W/m^2$) (RAUSCHENBACH, 1980).

Para um arranjo fotovoltaico com vários módulos em série e/ou paralelo a equação 2.3 pode ser reescrita da forma da equação 2.4:

$$I_{fv,a} = (I_{fv,an} + K_1 \Delta T) \frac{G}{G_n} \quad (2.4)$$

Onde $I_{fv,an}$ é a corrente nominal do arranjo fotovoltaico nas condições nominais (RAUSCHENBACH, 1980).

2.2 Influência da Temperatura e da Irradiância.

A irradiância e a temperatura da célula são fatores que influenciam, de forma determinante no funcionamento da célula fotovoltaica (LOPES, 2013).

2.2.1 Temperatura


O aumento da temperatura de uma célula fotovoltaica provoca um discreto aumento na fotocorrente, da ordem de $30 \mu\text{A}/^\circ\text{C.m}^2$, para valores baixos de tensão, sendo que este aumento é decorrente da diminuição da energia da banda proibida devido ao aumento da temperatura (CUBANE, 1994). Abaixo é apresentado um resumo em tópicos do efeito da temperatura.

Com o aumento da temperatura:

- i. A potência de saída da célula diminui;
- ii. A tensão de circuito aberto, V_{oc} diminui;
- iii. A corrente de Curto Circuito, I_{sc} varia muito pouco;
- iv. A corrente inversa de saturação, I_0 , varia.

O efeito da diminuição da tensão de circuito aberto V_{oc} , é apresentado na Figura 9.

Figura 9 - Variação da curva I-V do módulo fotovoltaico usado na simulação com diferentes temperaturas.



Fonte: Própria.

2.2.2 Irradiância


Uma mudança na Irradiância provoca uma variação proporcional na corrente de curto circuito I_{sc} , independente da tensão, que varia muito pouco em comparação com a corrente (ALCANTARA, 2010). Abaixo é apresentado um resumo em tópicos do efeito da variação da irradiância.

Com o aumento da irradiância na célula:

- i. A potência de saída da célula aumenta;
- ii. A tensão de Circuito Aberto, V_{oc} , varia pouco;
- iii. A corrente de Curto Circuito, I_{sc} , varia linearmente;
- iv. A corrente de saturação, I_0 , varia.

A corrente de curto-circuito, praticamente não varia com a temperatura da célula, apresentando uma variação linear com a irradiância incidente, como apresentado na Figura 10.

Figura 10 - Variação da curva I-V do módulo fotovoltaico utilizado na simulação com diferentes irradiâncias.



Fonte: Própria.

2.3 Efeitos do Sombreamento parcial nos painéis fotovoltaicos.

Em sistemas de energia solar fotovoltaica convencionais o sombreamento parcial é algo praticamente inevitável, podendo ser causado por vários fatores

naturais e obstáculos da própria edificação onde se encontra a instalação. A diminuição na potência de saída é proporcional à área sombreada e à irradiância, porém, essa afirmação só se confirma para uma única célula fotovoltaica. Quando se trata de módulos e arranjos fotovoltaicos a situação é bem diferente, não havendo uma linearidade entre as perdas de produção e a área sombreada (SÉRA, 2008). Quando uma célula se encontra sombreada, esta atua como uma carga, dissipando a corrente de entrada e criando os chamados pontos quentes. De forma a minimizar o efeito do sombreamento, são introduzidos os diodos de *by-pass*, que permitem a passagem da corrente sem danificar a célula (DZUNG, 2006). Portanto, a utilização de um diodo *by-pass* ligado em antiparalelo com as células sombreadas, evita com que a corrente do módulo seja limitada por uma célula em condições incompatíveis com as demais (VERMURU et al, 2012).


No entanto, o número de diodos de desvio em um módulo fotovoltaico é normalmente limitado, de modo que o sombreamento de uma única célula afeta um percentual considerável das células do módulo, pois o diodo desvia a corrente de todo o grupo ao qual está conectado (GUO et al, 2012).

A IEC (*International Electrotechnical Commission*) estabelece por Norma Técnica que os fabricantes de módulos fotovoltaicos devem usar no mínimo dois diodos *by-pass* por módulo.

A utilização de diodos *by-pass* se faz em grupos de células e não por célula para reduzir custos de produção do módulo, visto que tecnologicamente não há nenhum impedimento para a inclusão de um diodo por célula na construção dos módulos (BONIFÁCIO, 2010).

Em condições de sombreamento, arranjos série e/ou paralelo de painéis fotovoltaicos podem apresentar vários máximos locais em sua curva característica, mas apenas um deles é máximo global. A Figura 11 mostra a ligação dos diodos *by-pass* em um módulo fotovoltaico, onde cada diodo protege um conjunto de células fotovoltaicas.

Figura 11 - Ligação de diodos de *by-pass* em módulos fotovoltaicos



Fonte: (GTES, 2014).

A Figura 12 apresenta a curva característica Potência *versus* Tensão de um módulo que sofre influência do sombreamento parcial.

Figura 12 - Curva característica com sombreamento parcial.




Fonte: Adaptado de Solarize (2018).

2.4 Pontos de Máxima Potência em Painéis Fotovoltaicos

A baixa eficiência de conversão das células fotovoltaicas e o alto custo de instalação são os maiores obstáculos da geração desse tipo de energia. Visando atenuar esses obstáculos, uma estratégia é garantir que o máximo rendimento energético do sistema seja alcançado. O máximo aproveitamento da capacidade de energia elétrica de um módulo fotovoltaico é obtido quando o mesmo opera no ponto de máxima potência (MPP), e esse ponto varia de acordo com a irradiância e a temperatura à qual o módulo está exposto. Para garantir essa situação, faz-se necessária a utilização de uma técnica que rastreie este ponto, mesmo com variações meteorológicas. As técnicas baseadas nesse princípio são chamadas de técnicas de rastreamento do ponto de máxima potência (MPPT – *Maximum Power Point Tracking*) (SEGUEL, 2009). Essas técnicas consistem em adequar a tensão imposta ao painel fotovoltaico para que o mesmo opere no MPP, e ao mesmo tempo disponibilizar à carga sua tensão de operação. As características da curva tensão *versus* corrente dos painéis fotovoltaicos variam de forma não linear de acordo com o nível de irradiância e de temperatura, e isso torna complexa a tarefa de rastrear esse ponto, considerando-se ainda variações de carga (CANESIN et al, 2010). A Figura 13 apresenta a curva característica típica de um módulo fotovoltaico com sombreamento, com indicação do ponto de máxima potência.

Figura 13 - Curva característica de um painel fotovoltaico com indicação do ponto de máxima potência.



Fonte: Própria.

2.4.1 Técnicas Convencionais para o Rastreamento de Pontos de Máxima Potência

Segundo ESRAM (2007), as técnicas para o rastreamento dos pontos de máxima potência em painéis fotovoltaicos mais utilizadas são: Tensão de Circuito Aberto, Perturba e Observa (P&O – Perturbation and Observation) e Condutância incremental (IncCond – Incremental Conductance).

2.4.1.1 Técnica da Tensão de Circuito Aberto

Esta técnica é baseada no fato de que a tensão em potência máxima (V_{mp}) e a Tensão em circuito aberto (V_{oc}) têm aproximadamente uma relação linear independente de qualquer condição de irradiância e temperatura (ESRAM, 2007). A equação 2.5 mostra como é calculada a tensão em potência máxima.

$$V_{mp} \approx K.V_{oc} \quad (2.5)$$

Onde K , chamado fator de tensão, depende das características do arranjo fotovoltaico utilizado. Essa constante é geralmente calculada por meios empíricos, determinando o V_{mp} e V_{oc} para diferentes condições meteorológicas. E o valor dessa constante varia geralmente entre 0,7 e 0,8 (OJIMA, 2008). Quando encontrado K , é possível determinar o valor de V_{mp} . Para isso é preciso desconectar o conversor do arranjo fotovoltaico periodicamente e medir a tensão de circuito aberto V_{oc} . O valor de V_{mp} é utilizado como referência para ser comparado com a medição da tensão do painel e gerar um sinal de erro que é utilizado para ajustar a tensão de controle (SEGUEL, 2009).

Para implementar essa técnica é necessário que se utilize chaves adicionais para desconectar os painéis fotovoltaicos do conversor de potência para que as aquisições de V_{oc} possam ser feitas, o que resulta em uma falta momentânea de energia. Uma solução para esse problema seria, caso conversor possua uma chave (MOSFET, IGBT) em série com o painel, aproveitar a própria operação do conversor para fazer a medição de V_{oc} , isto é, quando a chave do conversor estiver aberta, mede-se V_{oc} . Outra desvantagem desta técnica é que não se pode calcular o novo MPPT até que a medição de V_{oc} seja realizada novamente. Porém a principal desvantagem desse método é a presença de erro em regime permanente devido ao fato de que a relação V_{oc} e V_{mp} não é constante (MASOUM et al, 2002).

Nessa técnica existem três parâmetros a serem considerados. O primeiro deles corresponde ao período de amostragem da tensão de circuito aberto (T_{ca}), ou seja, o intervalo de tempo em que é desligado o arranjo fotovoltaico do conversor de potência. O segundo é o período de amostragem (T_a), intervalo de tempo em que a tensão do painel é amostrada em funcionamento normal. O terceiro parâmetro corresponde ao ganho do algoritmo para essa técnica. Se o valor de T_{ca} é muito pequeno a produção de energia dos painéis será reduzida pelo aumento da frequência das perdas momentâneas de energia pelo tempo de desconexão. Se T_{ca} for muito grande o MPP não pode ser rastreado quando há mudanças em relação ao ambiente. T_a e o ganho estão relacionados com a velocidade de convergência e a estabilidade da técnica. Uma diminuição de T_a permite aumentar a velocidade de convergência embora aumente a ondulação de potência em regime permanente, podendo a técnica atingir a instabilidade para valores muito pequenos. Para os casos do ganho um aumento de seu valor aumentará a velocidade de convergência e acrescentará também a ondulação em regime permanente da potência de saída

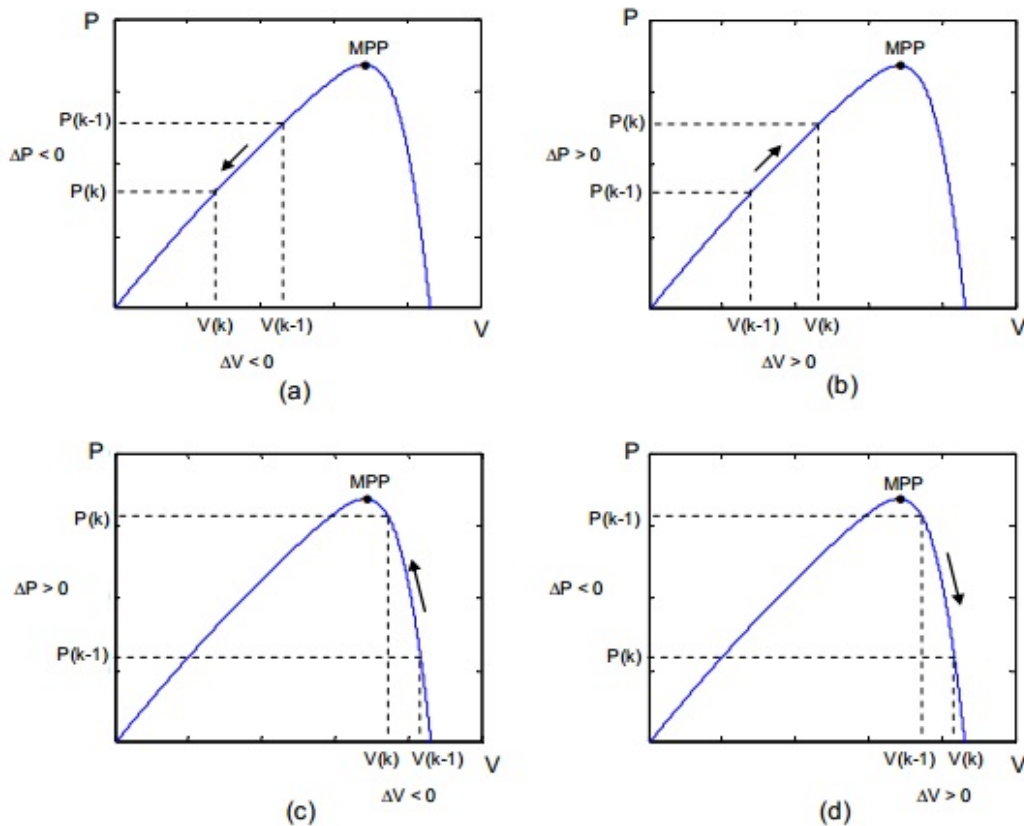
do painel, chegando a ser instável para valores muito grandes (SEGUEL, 2009).

2.4.1.2 Técnica Perturba e Observa

O método de busca por P&O (Hill Climbing) baseia-se no procedimento de perturbar a tensão operante nos terminais do painel num determinado sentido e observa se há um aumento ou uma diminuição na potência gerada. Se houver um aumento na potência, deve-se manter a perturbação no mesmo sentido, caso contrário, inverte-se o sentido da perturbação. Esse processo continua periodicamente, até mesmo quando o MPP é alcançado, dessa forma a tensão operante oscila em torno do MPP em regime permanente o que diminui a eficiência do método (MOÇAMBIQUE, 2012). Porém, quanto menor for o passo, mais lento será o algoritmo, comprometendo a eficiência em alguns casos como, por exemplo, quando ocorrem rápidas mudanças atmosféricas, o que acontece em dias de baixa incidência de luz solar (FEMIA, 2005). Para solucionar esse problema, são utilizados passos de tamanho variável, cujo tamanho diminui à medida que se aproxima do MPP (ESRAM, 2007).

Devido à sua fácil implementação essa é uma das técnicas mais utilizadas. Para exemplificar, a Figura 14.a mostra uma diminuição da tensão e em consequência o sistema se afasta do MPP pela esquerda. A Figura 14.b mostra uma variação positiva no valor da tensão e em consequência o sistema se aproxima do MPP pela esquerda. A Figura 14.c mostra uma diminuição da tensão e em consequência o sistema se aproxima do MPP pela direita. E por fim a Figura 14.d mostra uma variação positiva no valor da tensão e em consequência o sistema se afasta do MPP pela direita.

Figura 14 - Técnica Perturba e Observa.



Fonte: Seguel (2009).

Nessa técnica existem dois parâmetros a serem definidos. O primeiro é o período de amostragem (T_a) que, tal como na técnica anterior, corresponde ao intervalo de tempo em que é amostrada a tensão do arranjo fotovoltaico e, para o caso da técnica P&O, também da corrente do arranjo. O segundo é o tamanho da perturbação (ΔV), isto é, o range de tensão aplicada à tensão de referência. Com relação a ΔV , tem-se uma limitação prática que impede a escolha de perturbações muito pequenas. Tem-se que evitar que as perturbações na tensão de referência tenham a mesma ordem de grandeza que as oscilações presentes na tensão de barramento CC provocadas pelas não linearidades do conversor de potência e ruídos nas medições (AZEVEDO, 2007).

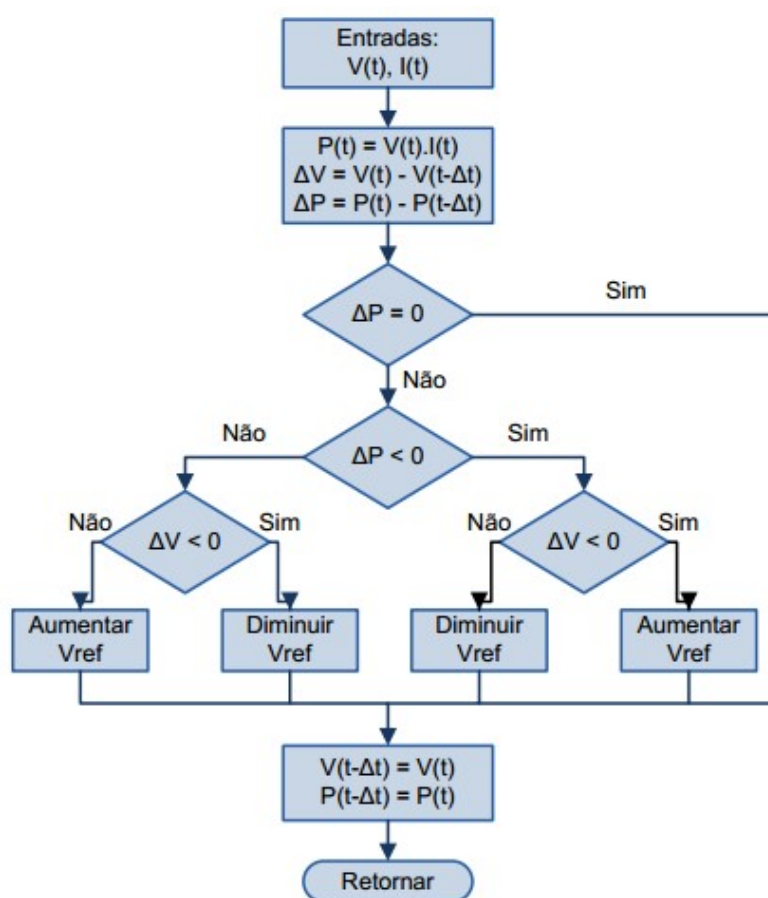
A escolha de um período de amostragem pequeno permitiria detectar rapidamente modificações nas condições meteorológicas, rastreamento em menor tempo um novo MPP. Entretanto, existe uma limitação para o valor mínimo de T_a imposta pela dinâmica do conversor de potência. O T_a deve ser escolhido como sendo superior ao tempo de estabilização da tensão de saída do conversor para

evitar a instabilidade da técnica MPPT (AZEVEDO, 2007).

As principais desvantagens dessa técnica são: a presença de erro em regime permanente, resposta dinâmica lenta e operação fora do ponto de máxima potência, caso ocorram mudanças rápidas na temperatura e na radiação solar (ESRAM, 2007).

A Figura 15 apresenta o fluxograma básico da técnica Perturba e Observa (CANESIN et al, 2010).

Figura 15 - Fluxograma Básico Técnica Perturba e Observa.



Fonte: Canesin et al (2010).

2.4.1.3 Técnica Condutância Incremental

A técnica da Condutância Incremental se baseia no princípio de que a derivada da curva Potência *versus* Tensão é zero no MPP (MOÇAMBIQUE, 2012).

A condutância instantânea I/V é comparada à condutância incremental, isto é, a variação da corrente em relação à tensão. Uma vez alcançado o MPP, o ponto de operação do painel fotovoltaico é mantido até que ocorra uma variação na corrente indicando uma mudança nas condições atmosféricas, então a tensão de referência é decrementada ou incrementada para a busca do novo MPP (ESRAM, 2007).

A derivada da Potência em relação à Tensão é dada pela equação 2.6:


$$\frac{\partial P}{\partial V} = \frac{\partial(V.I)}{\partial V} = I + V \frac{\partial I}{\partial V} \quad (2.6)$$

Dividindo cada membro da equação acima por V , tem-se:

$$\frac{1}{V} \frac{\partial P}{\partial V} = \frac{I}{V} + \frac{\partial I}{\partial V} \quad (2.7)$$

Como V é sempre positivo, o sinal da derivada da potência em relação à tensão é igual a $(I/V + dI/dV)$, ou seja, a soma da condutância instantânea (I/V) e a condutância incremental (dI/dV). Dessa forma é possível interpretar de qual lado da curva de potência o sistema se encontra e também se consegue distinguir quando o sistema está trabalhando no ponto de máxima potência, isto é, quando $dP/dV = 0$. Quando essa condição é atingida não é necessário alterar o ciclo de trabalho do conversor, pois o sistema já estará operando no MPP. Isso evita que o problema de oscilação do ponto de operação em torno do MPP (SEGUEL, 2009). A Figura 16 identifica a trajetória do ponto MPP com a variação da irradiância. Pode-se observar na Figura 16 que no ponto à direita do MPP a derivada é menor que zero, e que à esquerda do MPP a derivada é maior do que zero. Isto indica ao sistema que deve haver alguma alteração no valor da tensão para buscar a derivada igual a zero (MPP).

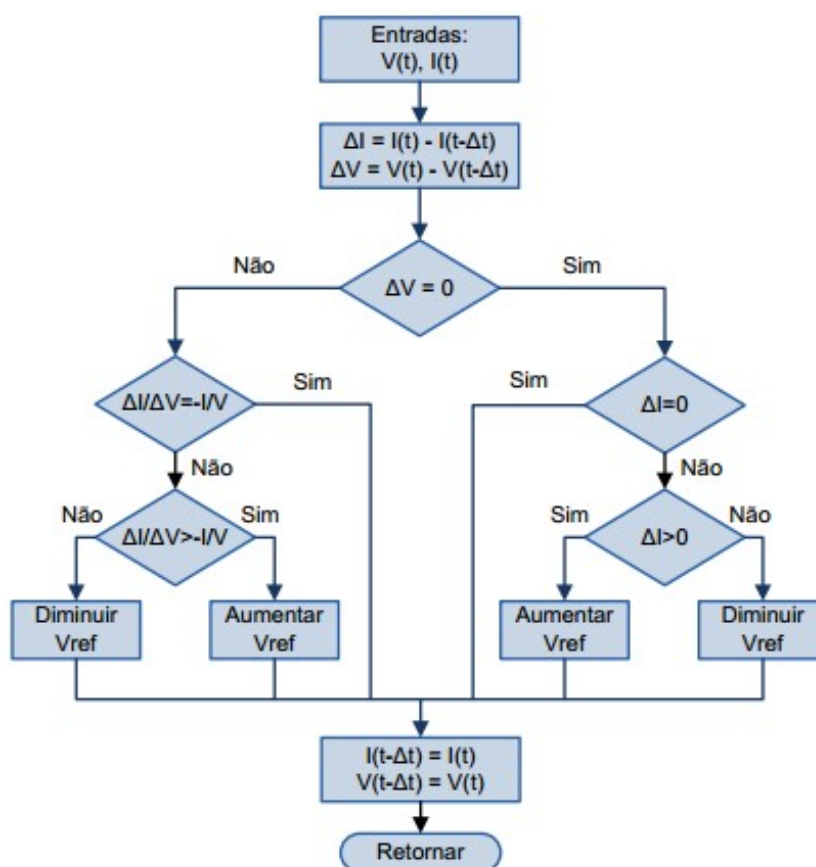
Figura 16 – Trajetória do ponto de máxima potência com a variação da irradiância.



Fonte: Seguel (2009).

A Figura 17 apresenta o fluxograma básico da técnica Condutância Incremental.

Figura 17- Fluxograma Básica Técnica Condutância Incremental.



Fonte: Canesin et al (2010).

2.4.2 Técnicas para rastreamento de pontos de máxima potência de painéis fotovoltaicos com sombreamento

O seguimento dos pontos de máxima potência em sistemas fotovoltaicos com sombreamento pode ser feitos de diversas maneiras, atualmente os inversores utilizados nas instalações podem possuir vários controladores MPPT, dessa forma os pontos de máxima potência são definidos a partir de cada *string* de módulos de forma individual por cada controlador, maximizando a potência até mesmo em situações de sombreamento (FEMIA, 2008). Entre as soluções que utilizam *software* embutido no controlado do inversor de um sistema fotovoltaico, algumas utilizam de ferramentas de inteligência computacional, e outras soluções de *software* optam por algoritmos mais simples baseados em minimizar as faixas de buscas de acordo com conclusões sobre as características das curvas características dos sistemas com

sobreamento parcial (FURTADO, 2016). Esses algoritmos mais simples são divididos basicamente em duas fases: a fase global, quando acontece propriamente a busca do MPP, e a fase local, quando o algoritmo apenas age para a manutenção do funcionamento do ponto de operação do sistema no valor pico de potência global (FURTADO, 2016).

Algumas técnicas se destacam na busca pelo ponto de máxima potência de painéis fotovoltaicos com sobreamento parcial, é o caso da Técnica de Chen e a Técnica de Boztepe.

2.4.2.1 Técnica de Chen et al. (2014)

Essa técnica apresenta uma solução focada apenas em arranjos fotovoltaicos ligados em série, sem módulos em paralelo, porém esse modelo se adapta também a arranjos série-paralelo. A principal característica deste modelo é a presença de um medidor de tensão para cada módulo do arranjo fotovoltaico, sendo assim, é possível diferenciar os módulos que estão sob influência do sobreamento, seja ele total ou parcial (CHEN et al, 2014).

A Técnica em sua fase inicial se baseia na técnica Perturba e Observa (P&O), um elemento provocando a detecção periódica da presença de um sobreamento, medindo os valores de tensão, visto que em ligações em série dos módulos a uma mesma temperatura, quando expostos a irradiações diferentes apresentam tensões diferentes em seus terminais, identificando o sobreamento (FURTADO, 2016).

Uma vez identificado o sobreamento inicia-se a fase global, o algoritmo tende a levar a tensão do arranjo para uma tensão onde nenhum dos módulos esteja desativado por seu diodo de bloqueio. O primeiro passo é testar se algum dos módulos está polarizado reversamente, ou seja, apresentando uma tensão negativa. Caso alguma tensão negativa seja detectada, a tensão de referência do controle do barramento será igual à tensão de circuito aberto do painel em condições normais de teste STC (FURTADO, 2016).

A condição em que nenhum módulo tenha tensão negativa é a ideal para que a medição das tensões de cada módulo identifique valores de irradiância diferentes no painel. Isto ocorre, pois, caso dois ou mais módulos estejam desativados por seus diodos de bloqueio não se pode afirmar se suas irradiações são iguais ou

diferentes, já que suas tensões são iguais (FURTADO, 2016).

Uma vez definida a tensão de referência é medida a potência e é chamado novamente o algoritmo Perturba e Observa até que um pico seja encontrado. O próximo passo da fase global salva o máximo local de maior tensão, ainda não se sabe se este é o máximo global. Estando o ponto de operação neste máximo local, o algoritmo faz a leitura das tensões de todos os módulos e analisa o número de tensões diferentes encontradas. Irradiações maiores geram picos de tensão maiores. Assim, este número de tensões diferentes dará o número de irradiações diferentes que podem gerar picos à esquerda do pico mais à direita da curva, ou seja, isso dará o máximo número de picos que a curva pode ter com tensões menores que o pico de maior tensão. Assim os módulos são divididos em grupos de mesma tensão e, posteriormente, executa um algoritmo interno de ordenação que posiciona os grupos de forma crescente de tensão. A partir desta ordenação, o algoritmo leva a tensão de referência do sistema para 85% da tensão de circuito aberto de um módulo nas condições de teste normais (STC) multiplicada pela diferença entre o número de módulos do painel e quantos desse módulo têm irradiações menor ou igual à cada irradiação de cada grupo. Cada possível pico começa e termina em mínimos locais coincidentes com a entrada de um grupo de módulos em condução. Ao alcançar cada referência, o algoritmo usa da técnica Perturba e Observa para passar por cada pico e encontrar o ponto de máxima potência.

2.4.2.2 Técnica de Boztepe et. al (2014)

Essa técnica também é analisada para painéis apenas com ligações em série, porém ela pode ser aplicada a qualquer sistema fotovoltaico (BOZTEPE et al, 2014).

A fase local desta técnica assim como na técnica de Chen também utiliza o algoritmo Perturba e Observa. Nesta técnica quando há um sombreamento, a fase global é iniciada. Neste algoritmo, a detecção do sombreamento é feita a partir da mudança brusca de potência. Se a derivada da potência em relação à tensão ultrapassar um certo limite, um sombreamento é detectado e a fase global é iniciada. Na fase global é apresentada a ideia de um limite máximo de tensão, avaliado estatisticamente, acima do qual não é necessário realizar a busca. Esse limite máximo da faixa de tensão de busca observado no estudo foi de 0,887 vezes o valor

da tensão de circuito aberto do painel em STC. Outra informação importante é o tamanho do passo de tensão usada na busca pelo ponto de máxima potência, que Boztepe et. al concluiu que para painéis com dois módulos em série o valor do passo não é no mínimo a metade do valor da tensão de circuito aberto destes módulos em STC e esse passo de tensão não é capaz de passar por mais de um ponto máximo de picos locais.

O primeiro passo ao se identificar o sombreamento é ler e salvar o ponto de operação, feito isso é necessário utilizar a definição de Triângulo de Operação de Potência e é calculado o valor da tensão mínima relacionando o valor de potência salvo e a corrente de curto-circuito em STC. O Triângulo de Operação de Potência é definido como uma região do plano tensão-potência com a forma de um triângulo retângulo limitado por uma reta com inclinação referente a uma corrente, este triângulo contém todos os possíveis pontos de operação de um painel fotovoltaico que ainda serão analisados durante uma busca com valores crescentes de tensão para qualquer configuração de irradiância e para qualquer temperatura. A ideia básica dos triângulos de Operação de Potência é que a inclinação da reta diminui à medida que a tensão dos pontos de operação aumenta. Isso significa que a corrente de cada ponto de operação de um sistema fotovoltaico, com qualquer condição de sombreamento, diminui à medida que a tensão destes pontos de operação aumenta (FURTADO, 2016).

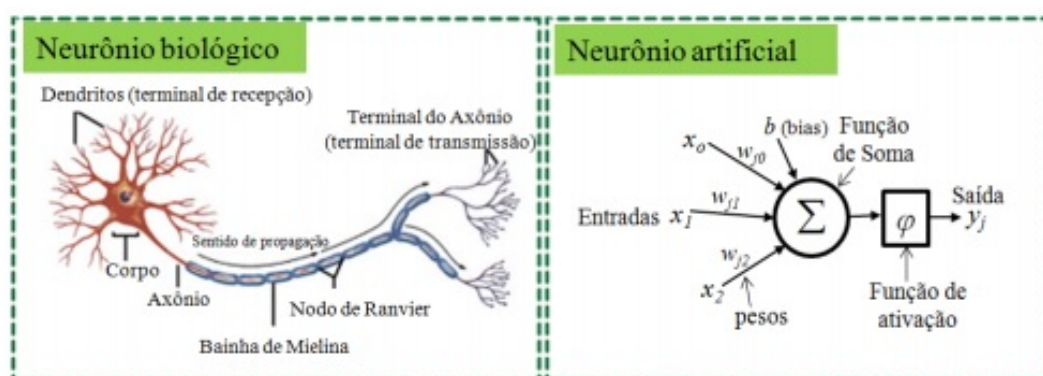
Uma vez calculada o valor dos limites de tensão, é definido um valor de referência de tensão através do cálculo da tensão mínima, neste ponto é medido o valor da potência e este valor é comparado com valor de potência salvo assim que houve a identificação do sombreamento, caso essa nova potência seja maior do que a potência anterior é salvo um novo ponto de operação, caso contrário o triângulo de operação de potência é atualizado e um novo valor de tensão mínima é calculada. A tensão de saída é atualizada recebendo o valor do passo definido anteriormente e é analisada o valor de potência, definindo o melhor ponto para a operação.

2.5 Redes Neurais Artificiais (RNA)

Redes neurais artificiais (RNA) são sistemas paralelos distribuídos, compostos por unidades de processamento simples (nós) que calculam

determinadas funções matemáticas. Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões. Na maioria dos modelos estas conexões estão associadas a pesos sinápticos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. As RNAs se baseiam no comportamento do neurônio biológico, isto é, buscam reproduzir a fisiologia do neurônio humano. Na Figura 18, observam-se as semelhanças entre um neurônio biológico e um computacional, em que as entradas do neurônio artificial (x_i) são análogas aos terminais de recepção do neurônio biológico (Dendritos), a Função soma desempenha o papel do Corpo Neuronal e a Função de Ativação representa as reações químicas ao longo do neurônio. A saída (y_j) equivale aos terminais do Axônio (transmissão). O índice i corresponde ao número de entradas de um neurônio e j indica o número de neurônios em uma rede. No modelo artificial tem-se ainda o conjunto de pesos (w_{ij}), que desempenha papel equivalente às reações das conexões sinápticas entre neurônios. Nestas conexões, cada dendrito possui uma reação diferente, estipulada pelas diferentes liberações químicas vindas dos neurônios pré-sinápticos, que poderão possuir caráter inibitório ou excitatório, ao neurônio pós-sináptico. Os pesos representam, portanto, a disposição inibitória ou excitatória dos sinais de entrada (FARIA, 2014)..

Figura 18 - Neurônio biológico e neurônio artificial.



Fonte: Faria (2014).

Este neurônio artificial é representado matematicamente pela equação 2.7.

$$y_j = \varphi \left(\sum_{i=1}^N w_{ij} x_i + b \right) \quad (2.7)$$

Sendo:

y_j = Saída da RNA;

φ = Função de Ativação;

N = Número de entradas da RNA;

w_{ij} = Peso Sináptico do neurônio i para o neurônio j ;

x_i = Entrada da RNA;

b = *bias* (polarização).


Uma RNA pode aproximar e interpolar dados multivariados de maneira rápida, suave e de forma compacta, o que, no caso de técnicas de programação convencionais poderiam exigir grandes bases de dados. As técnicas envolvendo o uso de RNAs são bem aceitas para a resolução de problemas lineares, não lineares, previsão e regressão estatística, reconhecimento de padrões e em diversas áreas do conhecimento (MATOS, 2011).

2.5.1 Redes Perceptrons de Múltiplas Camadas (MultiLayer)

Um *perceptron* é a forma mais simples de uma rede neural, com apenas um neurônio artificial e por esta razão só é capaz de solucionar problemas linearmente separáveis. A solução para problemas linearmente não separáveis se dá utilizando redes acíclicas como é o caso das redes *MultiLayer Perceptron* (MLP) no qual os neurônios são organizados em camadas com conexões unidirecionais entre eles, constituindo um conjunto de nós fonte, os quais formam a camada de entrada da rede, uma ou mais camadas escondidas e uma camada de saída (SOLIS et al, 2012).

Um modelo de MLP é mostrado na Figura 19. Os sinais de entrada são propagados camada por camada pela rede da entrada para a saída. A informação que chega dos dados de entrada é ponderada e processada por funções de ativação ao longo da estrutura da RNA até gerar uma saída.

Figura 19 - Rede Neural Artificial Multilayer Perceptron



Fonte: Medeiros (2004).

A seleção dos parâmetros para essa arquitetura consiste basicamente na determinação do número de camadas da rede e do número de neurônios em cada camada (MEDEIROS, 2004).

Três classes de função de ativação são usualmente utilizadas (FARIA, 2014):

i. Função Sinal: Neste tipo de função tem-se:

$$F(x) = 1 \quad \text{se } x > 0$$

$$F(x) = 0 \quad \text{se } x \leq 0$$

ii. Função Linear por Partes: Para esta função tem-se:

$$F(x) = 0 \quad \text{se } x \leq -a$$

$$F(x) = x + a \quad \text{se } -a > x > a$$

$$F(x) = 1 \quad \text{se } x \geq a$$

iii. Função Sigmoidal: é a função de ativação mais utilizada em RNAs. É definida como uma função monotônica crescente que apresenta propriedades assintóticas e de suavidade. Um exemplo de função sigmoidal é a função logística, definida pela equação 2.8:

$$F(x) = \frac{1}{1 + e^{-ax}} \quad (2.8)$$


Em que a é o parâmetro de inclinação da função. Esta função apresenta saídas dentro do intervalo entre 0 e 1.

Há casos em que é necessário que a saída da função sigmoidal esteja no intervalo entre -1 e 1. Para estes casos utiliza-se a função hiperbólica, que é dada pela equação 2.9.


$$F(x) = \tanh \frac{x}{2} = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.9)$$

A Figura 20 apresenta as formas gráficas das funções de ativação citadas.


Figura 20 - Funções de Ativação




(a) Função Sinal



(b) Função Linear por Partes



(c) Função Sigmoidal Logística



(d) Função Tangente Hiperbólica

Fonte: Faria (2014)

2.5.2 – Treinamento da Rede Neural Artificial (RNA)

O principal objetivo no treinamento de Redes Neurais Artificiais (RNA) é a obtenção de modelos com boa capacidade de generalização tendo como base um conjunto de dados. O aprendizado em RNAs está normalmente associado à capacidade de as mesmas adaptarem os seus parâmetros como consequência da sua interação com o meio externo. O processo de aprendizagem é iterativo e por meio dele a RNA deve melhorar o seu desempenho gradativamente na medida em que interage com o meio externo. O critério de desempenho que determina a qualidade do modelo neural e o ponto de parada de treinamento são pré-estabelecidos pelos parâmetros de treinamento e podem estar associados, por exemplo, ao valor do erro quadrático médio das respostas da RNA para um determinado conjunto de dados. Por sua vez, a capacidade de generalização das RNAs está diretamente associada à sua capacidade de dar respostas coerentes para dados não apresentados a ela durante o processo de treinamento. Esta característica foi por muito tempo considerada como inerente ao processo de treinamento da RNAs. No entanto, uma RNA com boa capacidade de generalização deve ter alguma forma de controle de generalização durante o processo de treinamento. Atualmente os fatores que influenciam a capacidade de generalização das RNAs são mais conhecidos e as pesquisas realizadas na área visam o desenvolvimento de modelos e técnicas que façam algum tipo de controle da generalização (MEDEIROS, 2004).

O processo de obtenção de uma RNA devidamente treinada quase sempre não é uma tarefa simples e geralmente requer um grande esforço por parte do projetista na determinação dos parâmetros que irão fazer com que uma Rede Neural Artificial aprenda adequadamente uma dada tarefa (MEDEIROS, 2004).

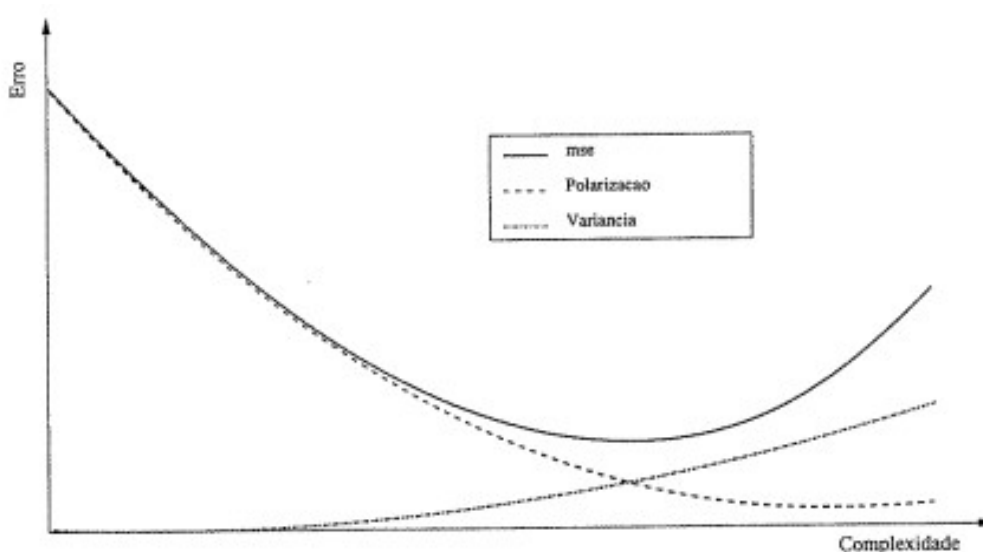
O processo de aprendizagem é considerado um processo difícil porque a procura da solução adequada ocorre em um universo de soluções possíveis de grande dimensão e a escolha entre as representações possíveis deve ser feita com base em uma determinada realização do conjunto de dados de treinamento. Isto porque uma rede com uma camada de entrada com (c_i) neurônios, uma camada escondida (oculta ou intermediária) com (C_h) neurônios e uma camada de saída com (c_o) , possui $n_w = [(c_i + 1) c_h + (c_h + 1) c_o]$ parâmetros livres (pesos e *bias*) e com isso o aprendizado com n_w parâmetros ocorre em um espaço n_w -dimensional (TEIXEIRA, 2001).

Em diversos problemas como regressão, classificação e predição, o conjunto de dados de treinamento é formado por pares entrada e saída (x_i, d_i) , sendo caracterizada previamente a saída desejada d_i para um determinado vetor de entrada x_i . O ajuste dos pesos deve modificar o valor da saída y_i obtida pela RNA de forma a minimizar o erro relativo à saída desejada d_i . Entretanto, a simples minimização do erro para os padrões de treinamento pode não levar a valores satisfatórios. O objetivo dos algoritmos de treinamento de Rede Neurais Artificiais deve ser o de aproximar as funções geradoras f_g dos dados e não simplesmente minimizar o erro do conjunto de dados de treinamento. O erro normalmente traz informações essenciais sobre o problema, mas para obter boas aproximações de f_g é preciso adicionar mais informações à solução do problema.

Diferentes realizações para um conjunto de treinamento podem fazer com que diferentes soluções sejam tomadas no universo possível de soluções, dada uma topologia de rede, principalmente quando os dados contêm algum ruído ou imprecisão. À variabilidade de soluções, dados conjuntos de treinamento diferentes para uma mesma tarefa, dá-se o nome de variância (GEMAN et al, 1992). Para se garantir boa capacidade de generalização, deve-se minimizar a variância das soluções. As soluções que apresentam alta variância geralmente apresentam superajuste da rede aos dados de treinamento, efeito conhecido como *overfitting* (MEDEIROS, 2004). Uma forma para solucionar o problema da alta variância é fazer uma redução do espaço de busca das soluções, reduzindo o número de parâmetros

livres da rede e com isso simplificando sua topologia. Mas a redução desse espaço de busca pode incorrer em outro problema que também afeta a capacidade de generalização, que é a polarização (GEMAN et al, 1992). A polarização das soluções ocorre quando, mesmo para diferentes realizações do conjunto de dados de treinamento, a solução resultante do processo de treinamento no espaço de dimensão reduzida é praticamente a mesma. As soluções que apresentam o problema de polarização são caracterizadas pelo sub-ajuste aos padrões de treinamento, efeito conhecido com *underfitting*. Com isso, a polarização das soluções é também algo a ser minimizado pra se garantir alta capacidade de generalização (MEDEIROS, 2004). A Figura 21 mostra de forma esquemática o comportamento da polarização e da variância diante da complexidade de uma rede.

Figura 21 - Representação da polarização e da variância em função da complexidade da RNA.



Fonte: Medeiros (2004).

Apesar de parecer contraditório, a minimização da variância para alcançar soluções de alta capacidade de generalização implica em aumento da polarização. Por sua vez, o aumento da polarização também prejudica a capacidade de generalização e deve ser minimizada. Com isso nota-se que deve existir um ponto de equilíbrio entre ambos efeitos (variância e polarização), conhecido na literatura como “o dilema entre a polarização e a variância” (GEMAN et al, 1992).

Sabe-se que os algoritmos de treinamento de RNAs que visam à minimização

do somatório dos erros quadráticos para ajustar os valores dos pesos da rede nem sempre conseguem obter soluções com alta capacidade de generalização. Existe uma necessidade de se ajustar a complexidade da rede em relação à complexidade necessária de um determinado problema de aprendizagem para se alcançar redes com altas capacidade de generalização (MEDEIROS, 2004).

A determinação da complexidade de uma RNA do tipo MLP não é uma tarefa simples, porém, por meio do controle da magnitude dos pesos demonstrou-se que esta informação é mais importante que o número de neurônios para determinação da complexidade de uma RNA (BARLETT, 1997). Com base nesta informação, existem técnicas de treinamento de RNAs que realizam o controle da complexidade das Redes Neurais utilizando a informação da magnitude dos seus pesos. Uma das técnicas conhecidas para se obter soluções de alta capacidade de generalização é por meio das técnicas de regularização (TIKHNOV, 1995). A ideia básica na qual consiste a técnica de regularização é estabilizar a solução por meio de algum funcional não-negativo que incorpore informação prévia sobre a solução. A forma mais comum de informação prévia envolve a suposição de que a função de mapeamento entrada e saída seja suave, no sentido de que entradas similares correspondam a saídas similares (MEDEIROS, 2004). A função de custo a ser minimizada é mostrada na equação 2.10.

$$J(w) = E_D(w) + \lambda E_S(w) \quad (2.10)$$

Onde λ é o parâmetro de regularização, um número real positivo considerado como um indicador de suficiência do conjunto de dados fornecidos como exemplos, quanto menor for esse valor mais irrestrita é a solução, ou seja, a solução depende totalmente dos padrões entrada-saída, na prática este termo assume um valor entre zero e ∞ de forma que haja um equilíbrio entre a amostra de dados e a informação prévia, se o valor de λ tender ao infinito indica que os exemplos não são confiáveis. $E_S(w)$ é o termo de Regularização, este termo depende das propriedades da função aproximada, é um valor que deve ser estimado, existem algumas técnicas para solucionar este problema, que não será exposto neste trabalho por fugir do escopo do mesmo, e $J(w)$ é a função de custo modificada a ser minimizada no processo de treinamento, E_D é o termo de erro padrão que mede o erro padrão entre resposta desejada e a resposta real obtida.

O uso de regularização no treinamento de Rede Neurais Artificiais necessita do ajuste do parâmetro de regularização λ , que determina a importância do termo de regularização, $E_S(w)$, durante o treinamento. Este parâmetro pode ser determinado empiricamente, porém isto implica em um esforço muito grande por parte do usuário e também algum conhecimento prévio da função geradora a ser modelada (MEDEIROS, 2004). Porém, há uma técnica conhecida como *Regularização Bayesiana* que foi desenvolvida para a otimização do parâmetro de regularização como parte do processo de aprendizagem da rede na fase de treinamento (MACKAY, 1992). Outro método de treinamento que foi testado e que será apresentado é o método de Levenberg-Marquardt.

2.5.3 – Algoritmo BackPropagation

O algoritmo *backpropagation* é um dos principais algoritmos de treinamento de redes neurais utilizados (BARBOSA, 2005).

O algoritmo *backpropagation* baseia-se no princípio do aprendizado por correção do erro, no qual o erro é retropropagado da camada mais externa para as camadas intermediárias da rede neural artificial. Consiste em duas etapas: Um sinal de entrada é aplicado e seu efeito se propaga através das camadas da rede neural artificial, produzindo uma saída, com pesos previamente fixados, na etapa seguinte os pesos são reajustados de acordo com a regra de aprendizado por correção de erro. A resposta fornecida pela rede é subtraída da resposta desejada, produzindo um sinal de erro, sendo esse sinal propagado de volta através dos mesmos neurônios do passo direto, mas no sentido contrário do fluxo de sinais das conexões. Os pesos são ajustados de forma que a resposta a ser produzida pela rede se aproxime da resposta desejada (BARBOSA, 2005).

Buscando uma resposta adequada de forma mais rápida, ou seja, para que o processo de cálculo dos pesos da rede neural artificial seja mais rápido são utilizadas técnicas que otimizam esse processo de retropropagação, os dois métodos explorados neste trabalho são o método regularização bayesiana e o método Levenberg-Marquardt.

2.5.4 – A Regularização Bayesiana

De modo geral, o treinamento de RNAs visa a redução do somatório dos erros quadráticos. Entretanto, a Regularização Bayesiana, acrescenta um termo adicional: a função de custo torna-se a equação 2.11.

$$F = \beta E_D + \alpha E_W \quad (2.11)$$

Onde o segundo termo da equação αE_W é o somatório dos erros quadráticos da rede e α e β são parâmetros de regularização da função objetivo. Com a técnica bayesiana adotada por este método, o treinamento com regularização dispensa o uso de um conjunto de validação para determinação do valor ótimo dos parâmetros de regularização (MEDEIROS, 2004).

A magnitude relativa dos parâmetros da função objetivo dita a ênfase do treinamento. Se α é muito menor que β , então o treinamento terá maior ênfase na minimização do erro para os dados de treinamento. Se α é muito maior que β , o treinamento irá enfatizar a redução dos valores dos pesos da rede, produzindo, então, uma resposta da rede mais suave (MEDEIROS, 2004).

O principal problema com a utilização de técnicas de regularização é a determinação dos melhores valores para os parâmetros da função objetivo (MACKAY, 1992).

Portanto, determinar o α e o β ótimos para a função de custo é a grande questão do método de Regularização Bayesiana. Baseado na informação do número efetivo de parâmetros calculado durante o processo de otimização, o parâmetro α determinará o grau de penalização da complexidade da norma dos pesos enquanto o parâmetro β determinará o grau de penalização do erro de treinamento.

Há alguns métodos que podem ser utilizados para uma aproximação desses dos valores de α e β , dentre as mais usadas se encontra o algoritmo GNBR (Gauss-Newton to Bayesian Regularization) (MEDEIROS, 2004). Esse algoritmo não será tratado neste trabalho porque foge do escopo da aplicação.

2.5.5 – Método de Treinamento Levenberg-Marquardt

O algoritmo de treinamento de redes neurais artificiais Levenberg-Marquardt é um método de otimização e aceleração da convergência do algoritmo *backpropagation* (BISHOP, 1995). Pode ser visto como um método de segunda ordem, pois utiliza informações sobre a derivada segunda da função de erro. Um detalhe importante sobre o método Levenberg-Marquardt é que ele pode ser tornar computacionalmente impraticável em RNAs muito grandes (HAGAN, 1994).

O algoritmo Levenberg-Marquardt faz uso da matriz Hessiana H , que é uma matriz quadrada das derivadas segunda de uma função. No método Levenberg-Marquardt se faz uma aproximação para essa matriz que é representada pela equação 2.12, determinada em função da matriz Jacobiana, que é uma matriz formada pelas derivadas parciais de primeira ordem de uma função, no caso da rede neural contém as primeiras derivadas dos erros em função dos pesos sinápticos, expressa em 2.13.

$$H = \frac{\partial^2 e(W)}{\partial W^2} \quad (2.12)$$

$$J = \frac{\partial e(W)}{\partial W} \quad (2.13)$$

Onde $e(W)$ é definido como na equação 2.14.

$$e(W) = \sum_{i=1}^n (y_i - y_{ei}) \quad (2.14)$$

Para uma rede neural artificial, a performance do treinamento é expressa em função da somatória dos erros quadráticos, portanto a matriz Hessiana pode ser escrita como na equação 2.15.

$$H = J^T(W).J(W) \quad (2.15)$$

Os pesos são atualizados utilizando a equação 2.16.

$$W(k + 1) = W(k) - [J^T(W).J(W) + \mu_k I]^{-1}.J^T.e(W) \quad (2.16)$$

Onde I é a matriz identidade e μ_k é a constante do método de Levenberg-Marquardt.

O parâmetro μ_k funciona como um fator de estabilização do treinamento, evitando passos muito grandes que possam levar a um erro de convergência (BARBOSA, 2005).

2.5.6 – Teste da RNA

Depois que a rede é treinada, e o erro está dentro de um nível aceitável, ela deve ser testada para verificar sua capacidade de generalização adquirida no treinamento, o conjunto de teste é utilizado para determinar o desempenho da rede com dados que não foram utilizados durante o treinamento. O desempenho da rede é uma boa indicação de seu desempenho real.

3. METODOLOGIA PROPOSTA

Como visto, os painéis fotovoltaicos apresentam características de tensão *versus* corrente não lineares, as quais variam de acordo com o nível de irradiância e de temperatura e isto torna a extração dos pontos de máxima potência uma tarefa muito complexa, principalmente quando há o efeito do sombreamento nos painéis.

Em condições de sombreamento, arranjos série/paralelo de painéis fotovoltaicos podem apresentar vários máximos locais em sua curva característica, mas apenas um dele é o máximo global, como foi apresentado na Figura 12.

Neste capítulo, será apresentada a metodologia proposta, ou seja, a aplicação de Redes Neurais Artificiais ao rastreamento de pontos de máxima potência de arranjos fotovoltaicos, como foi feita a montagem da base de dados para o treinamento e os testes da RNA e normalização dos da base de dados e por fim a configuração da Rede Neural Artificial.

3.1 Aplicação de RNA ao MPPT de Arranjos Fotovoltaicos

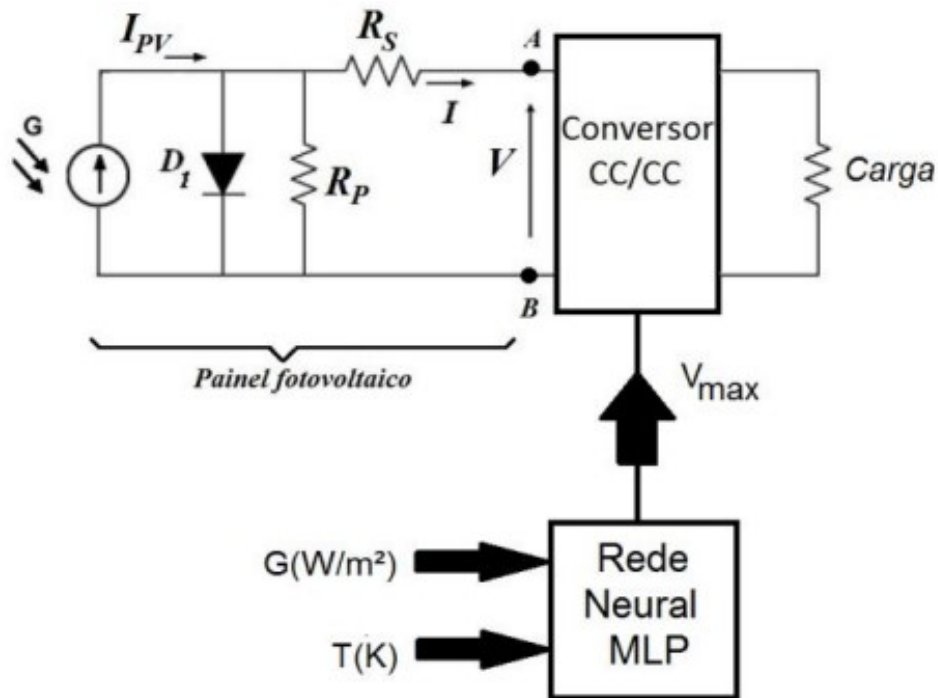
Existem várias técnicas que realizam a busca pelos pontos de máxima potência em painéis fotovoltaicos, e uma forma de realizar essa busca é utilizando as Redes Neurais Artificiais.

A partir de uma base de dados (contendo informações de entrada e saída) grande o suficiente para o aprendizado supervisionado da Rede Neural Artificial é possível que a rede seja capaz de encontrar esses pontos de maneira praticamente instantânea, e isto faz da rede neural uma boa estratégia para a resolução deste problema.

Visto que temperatura e irradiância são fatores que alteram a tensão no ponto de máxima potência, estas variáveis serão inseridas na Rede Neural Artificial que estimará o ponto de máxima potência. Na prática, essa rede deve ser ligada a um conversor CC-CC que se encarregará de impor esta tensão no painel, levando o sistema para o ponto ótimo de funcionamento (BASTOS et al, 1995).

A Figura 22 apresenta o modelo de uma célula conectada a um conversor CC-CC, que usa como referência valores extraído de uma Rede Neural Artificial esse valor de referência será responsável em alterar o ciclo de trabalho (*duty cycle*) do conversor, alcançando dessa forma o valor estipulado.

Figura 22 - Utilização da RNA para estimação do ponto de máxima potência.



Fonte: Villalva et al (2009).

3.2 Montagem da Base de Dados para o treinamento e teste da RNA.

Para a montagem da base de dados necessária para o treinamento e testes da RNA, foi desenvolvida uma plataforma utilizando o *softwares* MatLab/Simulink®, onde foram considerados dois módulos da empresa Canadian Solar, modelo CS6P=250M-EA, cujas características estão dadas na Tabela 3.1, ligados em série, computando assim uma potência pico de 500 W.

Tabela 3.1 - Dados do módulo fotovoltaico utilizado.

STC – 1000 W/m², AM 1.5, 25°C	CS6P-250M
Potência Máxima (P _{max})	250 W
Tensão de Máxima Potência (V _{mp})	30,4 V
Corrente de Máxima Potência (I _{mp})	8,22 A
Tensão em Circuito Aberto (V _{oc})	37,5 V
Corrente de Curto Circuito (I _{sc})	8,74 A
Número de Células	60

A potência máxima, que também é conhecida como potência pico, é a máxima potência entregue pelo painel, considerando uma irradiação de 1000 W/m², Coeficiente de Massa de Ar igual a 1,5 e temperatura de operação das células fotovoltaicas igual a 25 °C.

A tensão de máxima potência é o valor da tensão de operação para que o painel fotovoltaico trabalhe na potência máxima, assim como a corrente de máxima potência é o valor da corrente de operação para que o painel fotovoltaico trabalhe na potência máxima, levando em consideração as condições do ambiente.

A tensão em circuito aberto é a máxima tensão que o painel pode apresentar considerando as condições do ambiente. E a corrente de curto-circuito é a corrente máxima que o módulo fotovoltaico pode apresentar considerando as condições do ambiente. Estes parâmetros são importantes para o dimensionamento dos equipamentos de geração de energia solar fotovoltaica.

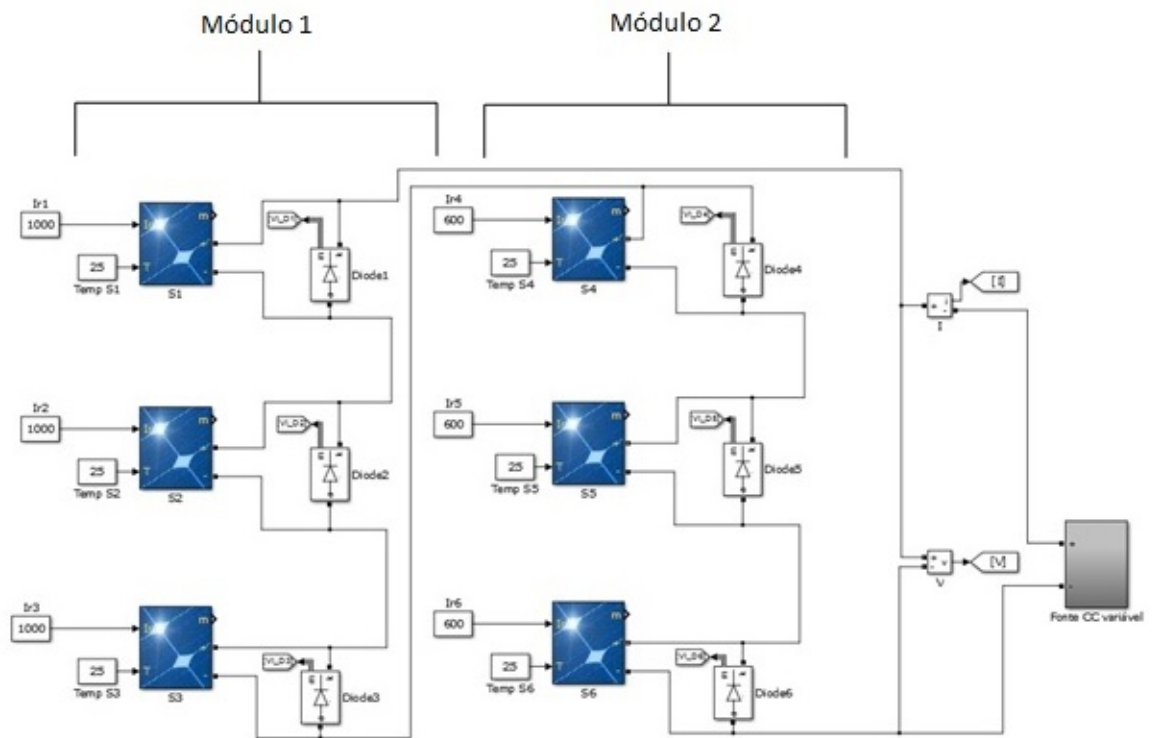
O número de células é a quantidade de células fotovoltaicas presente na arquitetura deste painel. Uma observação importante sobre as células fotovoltaicas é que a corrente gerada pelas células é proporcional ao tamanho (área) das células, portanto em alguns casos um painel com a mesma quantidade de células pode gerar mais ou menos corrente, ou seja, potências diferentes.

Cada um dos dois módulos foi dividido em três partes, simulando uma situação convencional onde geralmente a cada 20 células é incluído um diodo by-pass, portanto o painel foi dividido em 6 partes. Variando as condições de irradiação solar e temperatura foi possível determinar os pontos de máxima potência através das curvas características P x V e I x V para cada situação, gerando assim uma

base de dados suficientemente grande para o treinamento da Rede Neural Artificial.

A plataforma utilizada para a geração dessa base de dados é apresentado na Figura 23.

Figura 23 - Modelo utilizado para geração das curvas características.



Fonte: Própria.

A tabela 3.2 apresenta dados importantes para o desenvolvimento da simulação.

Tabela 3.2 - Dados para simulação do painel.

Corrente Gerada (A)	8,7669
Corrente de Saturação do Diodo (A)	1,4964e-10
Fator de idealidade do Diodo	1
Resistência Shunt Rsh (ohms)	329,41
Resistência Série Rs (ohms)	0,31657


Em cada parte do painel é possível a variação do valor da temperatura e da irradiação, dando assim a possibilidade de simular várias situações diferentes de sombreamento. A Figura 24 apresenta a curva característica de uma situação onde a

temperatura é de 25 °C, a irradiância em um dos módulos é de 1000 W/m² e a irradiância no outro módulo é de 600 W/m².

A primeira curva representa a característica Corrente x Tensão deste painel fotovoltaico. Como a irradiância não é a mesma em ambos os módulos do painel, apresenta-se de forma evidente o efeito do sombreamento para esse caso, essa variação no valor da tensão se dá devido a presença do diodo *by-pass* presente em cada conjunto de células. É possível também extrair desta curva o ponto de máxima potência, ou seja, para esse caso de sombreamento qual deve ser o par tensão-corrente para o painel entregar a maior potência. Esses dois valores são de extrema importância para a conclusão deste trabalho, visto que esses valores são usados como referências na saída da Rede Neural Artificial durante o processo de aprendizagem.

A segunda curva representa a característica Potência x Tensão deste painel fotovoltaico, nas condições citadas acima. Percebe-se que há somente um ponto de máxima potência, e é este que interessa.

Figura 24 - Curvas Características I x V e P x V.



Fonte: Própria.


Foram analisadas as curvas de várias situações diferentes, a fim de montar uma base de dados contendo as informações necessárias para o treinamento da Rede Neural Artificial. Como é possível inferir, as variáveis de entrada da rede neural

artificial são a temperatura, irradiância máxima e, para identificar o sombreamento, a variável utilizada neste trabalho foi a tensão de circuito aberto em cada situação de sombreamento, seja ele total ou parcial, uma vez que foi percebida uma pequena variação no seu valor toda vez que se mudava as condições de sombreamento. Portanto foram definidas três variáveis de entrada em cada amostra utilizada durante o treinamento da Rede Neural Artificial.

Para a saída da rede neural artificial a princípio foi utilizado somente o valor da Tensão de máxima potência, encontrada a partir das análises das curvas características, porém, os resultados não foram muito satisfatórios para vários parâmetros (número de camadas e números de neurônios) da rede neural artificial utilizada. Verificou-se que quando se incluía o valor da corrente de máxima potência os resultados convergiram para o esperado. Portanto como dados de saída foram utilizados duas variáveis, ou seja, a tensão de máxima potência e a corrente de máxima potência na situação considerada. Os detalhes sobre a configuração da rede neural Utilizada serão explicados mais a frente.


As Figuras 25 e 26 trazem, para exemplificar, mais algumas curvas utilizadas durante o processo de obtenção dos dados que foram usados durante o treinamento e teste da rede neural artificial utilizada.

Figura 25 - Sem Sombreamento, $G = 400 \text{ W/m}^2$ e $T = 35^\circ\text{C}$.



Fonte: Própria.

Figura 26 - Sombreamento em 1/3 do painel, $G_{max} = 800 \text{ W/m}^2$, $G_{min} = 400 \text{ W/m}^2$ e $T = 15^\circ\text{C}$.



Fonte: Própria.

As variações utilizadas durante o processo de montagem da base de dados segue explicado a seguir.

A princípio foi-se variando o valor da irradiância em cada parte do painel mantendo-se a temperatura constante, nisto foi-se coletadas as informações de tensão de circuito aberto, tensão de máxima potência e corrente de máxima potência. O valor da irradiação variou de 200 W/m^2 até 1000 W/m^2 , com intervalos definidos de 100 W/m^2 . Uma vez que todos os dados com esses valores de irradiância foram extraídos, mudou-se o valor da temperatura, que para esse trabalho variou de 15°C a 40°C , com intervalos definidos de 5°C , e novamente foram extraídos todas as informações para cada valor de irradiância variando novamente de 200 W/m^2 a 1000 W/m^2 , fazendo todas as configurações possíveis para as seis partes no qual o painel foi dividido. Todas essas variações geraram uma base de dados com 646 medições.

Abaixo na Tabela 3.3, segue um exemplo da organização desses dados. Nesse caso apresentado temos os valores das entradas e das saídas geradas utilizando a temperatura de 25°C , irradiância máxima de 1000 W/m^2 e a tensão de circuito aberto para cada caso seguindo a seguinte ordem:

- A primeira linha não há sombreamento parcial, todo o painel está exposto à irradiação de 1000 W/m²;
- A segunda linha da tabela apresenta os resultados do painel exposto a uma irradiação de 1000 W/m² porém com 1/6 exposto à uma irradiação de 200 W/m²;
- A terceira linha da tabela apresenta os resultados do painel exposto a uma irradiação de 1000 W/m² porém com 1/3 exposto à uma irradiação de 200 W/m²;

E assim os procedimentos se sucedem para todas as variações possíveis, ou seja, até a exposição de 5/6 do módulo à irradiação de 200 W/m² e apenas 1/6 do módulo com irradiação de 1000 W/m². A seguir mantém-se a variação máxima em 1000W/m² e muda-se o valor da irradiação do sombreamento para 400 W/m².

Tabela 3.3 – Parcial de dados extraídos do modelo utilizado.

	Módulo 1			Módulo 2						
	S1	S2	S3	S1	S2	S3				
T	G (W/m ²)			G (W/m ²)			Voc	Vmp	Imp	Pmax
25	1000	1000	1000	1000	1000	1000	74,99	60,920000	8,196800	499,349056
25	1000	1000	1000	1000	1000	200	74,17	50,000000	8,200000	410
25	1000	1000	1000	1000	200	200	73,36	39,200000	8,196000	321,2832
25	1000	1000	1000	200	200	200	72,55	28,400000	8,179100	232,28644
25	1000	1000	200	200	200	200	71,75	17,600000	8,143700	143,32912
25	1000	200	200	200	200	200	70,94	61,620000	1,664600	102,572652
25	1000	1000	1000	1000	1000	400	74,52	50,000000	8,206200	410,31
25	1000	1000	1000	1000	400	400	74,06	39,200000	8,196700	321,31064
25	1000	1000	1000	400	400	400	73,60	28,412500	8,177000	232,3290125
25	1000	1000	400	400	400	400	73,14	63,562500	3,355200	213,2649
25	1000	400	400	400	400	400	72,67	63,312500	3,321200	210,273475
25	1000	1000	1000	1000	1000	600	74,74	49,950000	8,215500	410,364225
25	1000	1000	1000	1000	600	600	74,48	64,950000	5,142100	333,979395
25	1000	1000	1000	600	600	600	74,21	64,075000	5,068800	324,78336
25	1000	1000	600	600	600	600	73,96	63,012500	5,025500	316,6693188
25	1000	600	600	600	600	600	73,70	62,062500	4,982600	309,2326125
25	1000	1000	1000	1000	1000	800	74,88	64,200000	6,866400	440,82288
25	1000	1000	1000	1000	800	800	74,76	63,337500	6,799600	430,669665

Uma vez que foram feitas todas as variações possíveis com os valores de irradiações, muda-se o valor da temperatura e o procedimento se repete, montando

assim uma base de dados grande o suficiente para o treinamento da rede neural artificial (RNA).

A tabela 3.4 apresenta o momento de transição entre uma irradiância e outra a fim de melhor exemplificar a montagem da base de dados.

Percebe-se que a variável que identifica o sombreamento, ou seja, a tensão de circuito aberto apresenta valores muito próximos um dos outros, isto é, a diferença no valor dessa variável de uma condição de sombreamento para outra é muito sutil, e isso poderia fazer com que a rede tenha dificuldades para generalizar o problema, para resolver esse problema e pensando também no melhor desempenho da rede neural todos os dados, de entrada e saída foram normalizados, com valores variando entre zero e um, com isso, essa diferença sutil entre os valores da tensão de circuito aberto, que identifica o sombreamento se tornou um pouco mais visível para a rede, garantindo a generalização do problema.

Tabela 3.4 – Parcial de dados extraídos do modelo utilizado.

	Módulo 1			Módulo 2						
	S1	S2	S3	S1	S2	S3				
T	G (W/m ²)			G (W/m ²)			Voc (V)	Vmp (V)	Imp (A)	Pmax (W)
40	400	400	400	400	400	400	68,230000	56,887500	3,303400	187,9222
40	400	400	400	400	400	200	67,880000	46,750000	3,300200	154,2844
40	400	400	400	400	200	200	67,500000	36,600000	3,296500	120,6519
40	400	400	400	200	200	200	67,140000	59,250000	1,701000	100,7843
40	400	400	200	200	200	200	66,760000	57,962500	1,684700	97,64942
40	400	200	200	200	200	200	66,400000	56,800000	1,668500	94,7708
25	900	900	900	900	900	900	74,670000	60,962500	7,399300	451,0798
25	900	900	900	900	900	200	73,910000	50,137500	7,390300	370,5312
25	900	900	900	900	200	200	73,150000	39,300000	7,383500	290,1716
25	900	900	900	200	200	200	72,400000	28,475000	7,368600	209,8209
25	900	900	200	200	200	200	71,640000	17,662500	7,332400	129,5085
25	900	200	200	200	200	200	70,880000	61,562500	1,664500	102,4708
25	900	900	900	900	900	400	74,260000	50,137500	7,390500	370,5412

3.3 Normalização da base de dados para treinamento e teste da RNA

Uma vez que foi gerada uma base de dados grande o suficiente para o

treinamento da Rede Neural Artificial, foi necessário ajustar os dados para o melhor funcionamento da RNA, normalizando-os. A importância da normalização nesse caso é que a variação da Tensão de Circuito Aberto dos módulos, que para esse trabalho é responsável em identificar o sombreamento, varia muito pouco em um caso de sombreamento para outro. Com os valores muito próximos um do outro seria mais difícil para a Rede Neural Artificial realizar a generalização do problema, mas com a normalização essa diferença é mais visível em termos de valores, ou seja, a normalização tornou a visualização dos dados mais clara, facilitando o processo de generalização da Rede Neural Artificial.

Na Tabela 3.5 é apresentado uma amostra dos dados reais e seus valores normalizados. As bases de normalização foram $T_{\min}=15\text{ }^{\circ}\text{C}$; $T_{\max}=40\text{ }^{\circ}\text{C}$; $G_{\min}=200\text{ W/m}^2$, $G_{\max}=1000\text{ W/m}^2$, $V_{oc\max}=77,54\text{ V}$, $V_{oc\min}=66,04\text{ V}$, $V_{mp\min}=16,3125\text{ V}$, $V_{mp\max}=67,975\text{ V}$, $I_{mp\min}=1,6185\text{ A}$ e $I_{mp\max}=8,3057\text{ A}$.

Tabela 3.5 – Parcial de dados reais e dados normalizados.

Dados Reais					Dados Normalizados				
T	G	Voc	Vmp	Imp	Tnorm	Gnorm	Vocnorm	Vmpnorm	Impnorm
40	400	66,4	56,8	1,6685	1	0,25	0,031304	0,783692	0,007477
20	1000	75,58	40,075	8,191975	0,2	1	0,829565	0,459956	0,982994
35	1000	72,16	47,8125	8,2157	0,8	1	0,532174	0,609727	0,986541
40	900	70,75	58,5875	6,8882	1	0,875	0,409565	0,818292	0,788028
25	900	74,67	60,9625	7,3993	0,4	0,875	0,750435	0,864263	0,864457
25	800	72,21	28,55	6,5523	0,4	0,75	0,536522	0,236874	0,737798
25	900	72,63	62,1375	3,3254	0,4	0,875	0,573043	0,887007	0,255249
15	900	77,04	52,4125	7,3856	0	0,875	0,956522	0,698766	0,862409

Podemos observar as pequenas diferenças dos valores da tensão de circuito aberto, Tensão de Máxima Potência e Corrente de Máxima Potência para vários casos de sombreamento parcial, e com a normalização essa diferença ficou mais visível para a rede neural artificial. Para as outras informações necessárias para o treinamento da rede, como a temperatura e a Irradiância, por serem valores com variações definidas, a normalização é importante somente para a busca do melhor desempenho da rede.

3.4 Configuração da Rede Neural Artificial


Uma vez gerada a base de dados através da simulação utilizando o software MatLab/Simulink®, onde o sistema foi exposto a diferentes condições de

sombreamento parcial e temperatura e realizado a normalização das informações para melhorar a precisão dos dados e tornar o treinamento da rede mais rápida, o próximo passo é a configuração da Rede Neural Artificial, ou seja, determinar os parâmetros para o treinamento e teste da RNA.

A rede implementada de início utiliza a configuração Multicamadas MLP (*multilayer perceptron*) com *backpropagation* (que permite a alteração dos pesos) com duas camadas ocultas com 13 neurônios cada, e método de treinamento regularização bayesiana. A quantidade de neurônios em cada camada foi definida através de testes de desempenho com vários valores diferentes, até que se obteve os melhores resultados com esse número de neurônios em cada camada. O número de camadas ocultas também foi definido através de testes realizados e observou-se que, por se tratar um problema com alto grau de não-linearidade, a melhor solução encontrada foi a utilização de duas camadas ocultas. Encontrar na saída da rede o valor da tensão de máxima potência (V_{mp}) é o único objetivo da rede neural artificial. Entretanto, na etapa de treinamento verificou-se a obtenção de melhores resultados utilizando no treinamento mais um dado de saída, no caso a corrente de máxima potência. Porém, no cálculo da potência entregue pelo sistema, o valor da corrente de máxima potência utilizada para o cálculo da potência máxima não foi extraída da Rede Neural Artificial, e sim extraída do gráfico referente àquele grau de sombreamento. Conhecendo o valor da tensão de máxima potência disponibilizada pela RNA para determinada condição de sombreamento, encontrou-se respectivo valor da corrente e calculou-se a máxima potência daquela condição. Portanto, a saída corrente de máxima potência aplicada na Rede Neural Artificial foi utilizada somente para auxiliar na busca pelos melhores resultados dos valores das tensões de máxima potência.

Os efeitos nos resultados ao considerar como saída da RNA apenas a tensão de máxima potência comparados a considerar tensão e corrente serão apresentados no capítulo 4. A Figura 27 apresenta as características da Rede Neural utilizada.

Figura 27 - Configuração da RNA utilizada.



Fonte: Própria.

Todos os dados de entrada e saída foram normalizados com valores entre zero e um, como foi explanado em um tópico anterior, para um melhor desempenho da rede neural. A função de ativação utilizada foi a função logística, a matriz de peso foi inicializada com valores aleatórios e o número de épocas de treinamento igual a 1000. Foram utilizadas 554 amostras para o treinamento da RNA e 92 amostras para teste, sendo que o método de treinamento inicialmente utilizado foi o de Regularização Bayesiana, que dispensa dados de validação. Também foi avaliado o método *Levenberg-Marquardt*, porém os resultados obtidos não foram melhores como será visto posteriormente. para esse método de treinamento.

Os outros parâmetros utilizados para a implementação da RNA utilizada são apresentados seguir.

```
net.trainParam.epochs = 1000; %% Número máximo de épocas treinamento
net.trainParam.goal = 1e-5; %%Objetivo do desempenho
net.trainParam.mu = 0.0005; %%Parâmetro de ajuste
net.trainParam.mu_dec = 0.1; %%Decréscimo do parâmetro de ajuste
net.trainParam.mu_inc = 10; %%acrécimo do parâmetro de ajuste
net.trainParam.mu_max = 1e10; %%parâmetro de ajuste máximo
net.trainParam.max_fail = 0; %%Máxima falha de validação
net.trainParam.min_grad = 1e-7; %%Performance mínima para o gradiente
net.trainParam.show = 25; %%Épocas entre as amostragens
net.trainParam.showCommandLine = false; %%Gerar linha de comando
net.trainParam.showWindow = true; %% Mostrar janela de treinamento
net.trainParam.time = inf; %%Máximo tempo de treinamento
```


4. RESULTADOS

Muitos modelos (número diferentes de camadas ocultas e número de neurônios por camada) de Redes Neurais Artificiais foram utilizados e incessantemente testadas a fim de obter os melhores resultados possíveis com a base de dados disponível. A seguir serão apresentados os melhores resultados para cada configuração de Rede Neural Artificial Testada.

Como foi dito em capítulos anteriores, o único dado que se busca na saída da Rede Neural Artificial utilizada é o valor da Tensão de Circuito Aberto, portanto o primeiro passo foi montar uma base de dados com somente uma saída, justamente a Tensão de Máxima Potência. Alguns exemplos dos resultados obtidos quando se utilizou somente esta saída serão apresentados a seguir. A princípio o método de treinamento utilizado foi o da Regularização Bayesiana, em outro momento serão apresentados os dados utilizando o método Levenberg-Marquardt (default) para efeito de comparação.


As Figuras 28 e 29 apresentam uma comparação entre os valores normalizados esperados, ou seja, os valores conhecidos das tensões de máxima potência e os valores obtidos pela RNA para as 92 amostras de teste.

Figura 28 - Comparação dos resultados da RNA com os resultados esperados e Regularização Bayesiana.



Fonte: Própria.

Figura 29 - Erro individual apresentado pela RNA com Regularização Bayesiana



Pode-se reparar, a partir das figuras apresentadas, que em alguns pontos os valores apresentados pela Rede Neural Artificial são aceitáveis, mas em grande parte os valores calculados pela RNA possuem muita diferença com os dados esperados.

O valor do Erro quadrático médio para essa configuração foi de 0,0247, que retorna um erro médio de 15,71%.


Considerando o valor do erro elevado, buscou-se testar outra configuração de Rede Neural Artificial. Optou-se a princípio por trocar o método de treinamento utilizado anteriormente pelo método padrão fornecido pelo Matlab, que é o método Levenberg-Marquardt.

Para essa nova configuração, utilizando o método de treinamento Levenberg-Marquardt, houve uma alteração no número de neurônios, na primeira camada passou de 13 para 8 neurônios, enquanto na segunda camada o número passou de 13 para 12 neurônios, configuração que possibilitou a obtenção de melhores resultados. Para esse método foi necessário estipular uma porcentagem de dados para treinamento, validação e testes, e os valores utilizados foram 70% (458 amostras), 16% (96 amostras) e 14% (92 amostras), respectivamente. A Figura 30 mostra os valores normalizados dos resultados obtidos com a nova RNA e os resultados esperados. Já a Figura 31 apresenta o erro obtido utilizando a RNA com treinamento pelo método Levenberg-Marquardt.

Pode-se observar através das Figuras 30 e 31 que em alguns pontos o erro apresentado é muito grande.


O valor do erro quadrático médio para essa configuração é de 0,0223, que retorna um erro médio de 14,9%, sendo um valor muito próximo do método anterior.

Figura 30 - Comparação dos resultados da RNA com treinamento Levenberg-Marquardt e os resultados esperados.



Fonte: Própria.

Figura 31- Erro Individual das amostras apresentada pela RNA utilizando o método Levenberg-Marquardt.




Fonte: Própria.

A fim de diminuir ainda mais erro encontrado, optou-se em aumentar o número de saídas da Rede Neural, ou seja, foi acrescentado na saída, além do valor da tensão de máxima potência, o valor da corrente de máxima potência. Novamente

a rede foi treinada com os dois métodos apresentados, o método da Regularização Bayesiana e o método de Levenberg-Marquardt.

A Figura 32 apresenta os resultados com o treinamento feito utilizando a técnica de regularização bayesiana, considerando agora como saída, durante o treinamento, a tensão de máxima potência e a corrente de máxima potência.


Figura 32 - Comparação dos resultados da RNA com os resultados esperados Regularização Bayesiana.



Fonte: Própria.

Os erros para essa configuração é apresentado na Figura 33.

Figura 33 - Erro individual apresentado pela RNA Regularização Bayesiana.




Fonte: Própria.

Observa-se que o erro diminui quando comparados com os resultados apresentados quando se utiliza somente a tensão de máxima potência como saída.

O valor do erro quadrático médio desta configuração é 0,0037, que retorna um erro médio de 6% que é um valor muito menor se comparado com a rede com apenas uma saída.


Para efeito de comparação também foi realizado o teste utilizando a tensão de máxima potência e a corrente de máxima potência para o método de treinamento padrão do Matlab®, o método Levenberg Maquartd. Os resultados são apresentados pelas Figuras 34 e 35.

Figura 34 - Comparação dos resultados da RNA com os resultados esperados Levenberg-Marquardt.



Fonte: Própria.

Figura 35 - Erro Individual das amostras apresentada pela RNA utilizando o método Levenberg-Marquardt.




Fonte: Própria.

O valor do erro quadrático médio para essa configuração é de 0,0067, que retorna um erro médio de 8,18%, um valor consideravelmente melhor quando comparado à rede neural com apenas uma saída, porém pior quando comparado com o erro médio encontrado quando utilizado o método de Regularização Bayesiana que foi de 6%.

A partir do melhor resultado encontrado foi feito uma nova comparação com os valores de máxima potência conhecida e a potência que o sistema entregaria se a tensão utilizada como tensão de máxima potência fosse a tensão retirada do resultado do processamento da Rede Neural Artificial. Vale frisar que neste ponto não foi utilizada o valor de corrente encontrado no processamento da RNA, o valor da corrente utilizada para o cálculo da potência foi encontrando a partir das curvas características das diversas variações climáticas, lá localizou-se o valor da tensão encontrada a partir do processamento da Rede Neural Artificial e foi recolhido o valor de corrente correspondente àquele valor de tensão. A utilização da corrente de máxima potência como saída da rede foi somente para melhorar o desempenho da rede neural artificial


As Figuras 36 (gráfico em linhas) e 37 (gráfico em colunas) trazem um comparativo entre essas potências, e com isso é possível analisar o desempenho da Rede Neural Artificial.

Figura 36 - Comparação em linhas entre a potência máxima conhecida e a potência obtida a partir do valor de tensão do processamento da RNA.



Fonte: Própria.


Figura 37 - Comparação em colunas entre a potência máxima conhecida e a potência obtida a partir do valor de tensão do processamento da RNA.



Fonte: Própria.

É possível perceber, analisando as Figuras 36 e 37, que o desempenho da rede é satisfatório na maioria dos casos, fazendo com que o valor da potência entregue pelo painel (potência proveniente do valor de tensão retirado do processamento da rede neural) seja próximo do valor máximo esperado (potência máxima conhecida). Somente em alguns poucos casos houve perdas consideráveis no valor de potência, e isso acontece quando há uma variação muito grande na curva característica, ou seja, o valor do máximo global é muito próximo do valor de um mínimo local. A Figura 38 mostra um caso onde pode acontecer perdas consideráveis no valor de potência.

Figura 38 - Mínimo local próximo ao Máximo Global.




Fonte: Própria.

Uma outra forma de apresentar o desempenho da rede neural artificial utilizada é comparando os valores de tensão de máxima potência conhecidos e os valores de tensão de máxima potência provenientes do processamento da rede neural artificial de forma mais direta, como apresentado nas Figura 39 ($G_{\max} = 1000 \text{ W/m}^2$ sem sombreamento e Temperatura = $^{\circ}\text{C}$, 15), Figura 40 (com $G_{\max} = 1000 \text{ W/m}^2$, $G_{\min} = 800 \text{ W/m}^2$ em 5/6 do painel e Temperatura = 35°C), Figura 41 ($G_{\max} =$


1000, $G_{\min} = 400$ em 1/6 do painel e Temperatura = 35°C) e Figura 42 ($G_{\max} = 1000$, $G_{\min} = 200$ W/m² em 1/2 do painel e Temperatura = 30°C).

Figura 39- Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).




Fonte: Própria.

Figura 40 – Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).




Fonte: Própria.

Figura 41 – Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).



Fonte: Própria.

Figura 42 – Comparação entre o resultado do processamento da RNA (preto) e do valor real (vermelho).



Fonte: Própria.

É possível perceber que o resultado do processamento da RNA é capaz de buscar os pontos de máxima potência dos painéis fotovoltaicos com sombreamento parcial.

5. CONCLUSÕES

O estudo teve como objetivo validar a possibilidade de usar redes neurais artificiais na determinação do ponto de máxima potência em painéis solares com sombreamento parcial.

Para compreensão adequada dos aspectos que foram tratados na dissertação, foram apresentados os conceitos de geração elétrica fotovoltaica, a influência da irradiância e temperatura no desempenho de um módulo fotovoltaico, e a influência de sombreamento parcial no comportamento de arranjos (painéis) fotovoltaicos.

Considerando que utilizar-se-ia redes neurais artificiais para determinação da tensão de obtenção de máxima potência do arranjo, também foi apresentada uma conceituação base de redes neurais.

Para a geração da base de treinamento da rede, foram utilizados dois módulos solar em série, já disponibilizados no Simulink/matlab®, modelo CS6P=250M-EA. Inúmeras simulações geraram a base de dados, sendo a maioria utilizada para treinamento e uma parcela menor para testes. Como dados de entrada, foram considerados a irradiância, a temperatura, e a tensão de circuito aberto. Este é um fator limitante da configuração escolhida: deve-se ser capaz de obter a tensão de circuito aberto, o que é facilmente alcançado se o painel conecta-se a um conversor de potência tipo abaixador (buck) ou elevador-abaixador (buck-boost). Para um conversor elevador, faz-se necessário a introdução de uma chave em série que de forma controlada abra o circuito sem danos ao sistema.

Duas técnicas de treinamento foram testadas para determinar os pesos sinápticos da RNA, ou seja, treinar a rede neural artificial: regularização bayesiana, e o método de Levenberg-Maquartd. A regularização bayesiana proporcionou resultados ligeiramente melhores que Levenberg-Maquartd. Também foi verificada a influência no resultado de usar apenas uma saída na etapa de treinamento da RNA – a tensão, ou adicionar mais uma saída, apenas para treinamento – a corrente. Esta última condição levou a melhores resultados de obtenção de potência.

A partir dos resultados mostrados conclui-se que uma Rede Neural Artificial bem treinada, ou seja, com grande capacidade de generalização e com as considerações adequadas, pode representar a função que maximiza a potência de saída de um painel fotovoltaico. As informações empregadas para treinamento da rede se

mostraram suficientes para identificar a tensão de operação com máxima potência. O erro de identificação na maioria das situações foi pequeno, podendo ser desprezado. O erro médio quadrático no resultado de melhor técnica foi de 6%. O número de amostras da etapa de treinamento cujo erro foi maior que 20% não se apresentou significativo.

Mostrou-se, portanto, que RNA são capazes de atuar como método de rastreamento de pontos de máxima potência (MPPT) em sistemas de energia solar fotovoltaica submetida a condições de sombreamento parcial ou total. O tempo de resposta é praticamente instantâneo, com menos oscilações do que as técnicas convencionais de rastreamento de pontos de máxima potência.

Como continuidade do estudo, pode-se elencar:

- Avaliar outras técnicas de determinação das características da RNA;
- Minimizar a RNA sem perda de generalidade;
- Integrar, por simulação, a RNA a um sistema conversor para simulações com variações diferenciadas em relação ao treinamento e avaliação de resultados.
- Adequar o desenvolvimento a uma aplicação real.

Este trabalho gerou uma produção científica no VIII Encontro Científico de Física Aplicada e foi publicado pela editora Blücher.

REFERÊNCIAS

ALCANTARA, S. M. F. Desempenho de um Pannel Fotovoltaico de Baixa Tensão, Acoplado ao Protótipo de um Conversor DC/DC Topologia Booster. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte, 2010.

ANEEL. Agência Nacional de Energia Elétrica (ANEEL). Unidades consumidoras com geração distribuída com Tipo de Geração: UFV. Disponível em: http://www2.aneel.gov.br/scg/gd/gd_fonte_detalhe.asp?tipo=12&pagina=1. Acesso em 02 fev. 2018.

AZEVEDO, G. M. DE SOUZA, Sistemas de Conversão de Energia Fotovoltaica com compensação Baseada em Corrente e Tensão. Dissertação de Mestrado, Universidade Federal de Pernambuco, Recife, Setembro de 2007.

BABU, T. SUDHAKAR; RAJASEKAR, N.; SANGEETHA, K. Modified particle swarm optimization technique based maximum power point tracking for uniform and under partial shading condition. Applied Soft Computing, v. 34, p. 613-624, 2015.

BARBOSA, A. H.; FREITAS, M. S. R.; NEVES, F. A. Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais. Rem: Rev. Esc. Minas, Ouro Preto, v. 58, n. 3, p. 247-255, Sept. 2005 Available from <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0370-44672005000300011&lng=en&nrm=iso>. access on 06 Feb. 2018. <http://dx.doi.org/10.1590/S0370-44672005000300011>.

BARTLETT, P. L. For valid generalization the size of the weights is more important than size of the network. In M. C. Mozer, M. I. Jordan, & T. Petsche. Advances in Neural Information Processing System, volume 9, pp. 134. The MIT Press. 1997.

BASTOS, R. F.; MOÇAMBIQUE, E. M.; MACHADO, R. Q.; AGUIAR, C. R. Rede Neural Artificial aplicada na busca do ponto de máxima potência em painéis fotovoltaico. São Carlos. Congresso Brasileiro de Automática, 2012.

BISHOP, C. M. Neural Networks for Pattern Recognition. Clarendon Press, Oxford. 1995.

BISHOP, C. M.; Pattern Recognition and Machine Learnig. Singapore: Springer, 2006. 749p.

BONIFÁCIO, P. J. S. Seguidor Fotovoltaico: Uma variação P&O – Simulação e Prototipagem. Dissertação de Mestrado, Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2010.

BOZTEPE, M. et al. Maximum power point tracking scheme for pv systems operating under partially shaded conditions. IEEE Transactions On Industrial Electronics, v. 61, p. 3302–3312, 2014.

CANESIN C. A., SAMPAIO, L. P., JUNIOR L. G., DE BRITO M. A. G. Avaliação das Principais Técnicas para Obtenção de MPPT de Painéis Fotovoltaicos. Universidade Estadual Paulista – UNESP, Ilha Solteira, 2010.

CARNEIRO, J. Módulos Fotovoltaicos Características e Associações. Universidade do Minho, Escola de Ciências, Departamento de Física, 2010a.

COELHO, D. C. Proposta de Conversor para Rastreamento da Máxima Potência de Operação de pequenos Sistemas de Geração de Energia Elétrica. 2009. 124 f. Dissertação (Mestrado) -Universidade Federal De Santa Catarina, Florianópolis, 2009.

CHEN, K. et al. An improved mppt controller for photovoltaic system under partial shading condition. IEEE Transactions On Sustainable Energy, v. 5, p. 978–985, 2014.

CHUCO, B. Otimização da potência de operação em sistema isolado fotovoltaico usando técnicas de inteligência artificial. 2007. 112 f. Dissertação (Mestrado) – Universidade Federal do Mato Grosso de Sul, Campo Grande, 2007.

CRESESB – CENTRO DE REFERÊNCIA PARA ENERGIA SOLAR E EÓLICA
SERGIO DE SALVO BRITO, CENTRO DE PESQUISA DE ENERGIA ELÉTRICA.
Energia Solar Princípios e Aplicações, 2006.

CUBANE, J. J. Estudo do Efeito da Temperatura no Rendimento das Células Solares. Monografia de Graduação. Universidade Eduardo Mondlane, Faculdade de Ciências – Departamento de Física, 1994.

DZUNG D N; BRAD L.. Modeling and simulation of solar PV arrays under changing illumination conditions. IEE COMPEL, pp 16-19, 2006.

ESRAM, T. and CHAPMAN, P. L. Comparison of Photovoltaic Array Maximum Power Point Tracking Techniques. IEEE Transactions on Energy Conversion, vol. 22, no. 2, pp. 439-449, junho 2007.

FARIA, W. A. Estudo do Sombreamento Parcial em Módulos Fotovoltaicos através da Resistência Série e das Redes Neurais Artificiais. 2014. 133 f. Dissertação (Mestrado), Universidade Federal de Uberlândia, Uberlândia, 2014.

FEMIA, N. et al. (2005). Optimization of Perturb and Observe Maximum Power Point Tracking Method. In: IEEE Transactionson Power Electronics, 2005, v. 20, no 4. P.963-973.

FEMIA, N. et al. Distributed maximum power point tracking of photovoltaic arrays: novel approach and system analysis. IEEE Transactions On Industrial Electronics, v. 55, p. 2610–2621, 2008.

FURTADO, A. M. S. Técnicas de seguimento do ponto de máxima potência para sistemas fotovoltaicos com sombreamento. 2016. 133 f. Dissertação (Mestrado), Universidade Federal de Pernambuco, 2016.

GEMAN, S.; BIENENSTOCK, E.; DOURSAT, R. Neural networks and bias/variance dilemma. Neural Computing, 1-58 1992.

GTES. Manual de engenharia para sistemas fotovoltaicos. [s.l: s.n.]. Disponível em: .

http://www.cresesb.cepel.br/publicacoes/download/Manual_de_Engenharia_FV_2014.pdf.

GUO, S.; WALSH, T. M.; ABERLE, A. G.; PETERS, M. Analysing Partial Shading of PV Modules by Circuit Modelling. IEEE, Photovoltaic Specialists Conference (PVSC), pp. 2957-2960, 2012.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. Neural Networks, IEEE Transactions on, v.5, n.6, p.989-993, 1994.

HALLIDAY, D.; RESNICK, R.; WALKER, J. Fundamentos de Física – Óptica e Física Moderna. 8ª Edição. LTC, 2011. P. 179.

IEA. INTERNACIONAL ENERGY AGENCY. Trends 2015 in photovoltaic applications. Paris, França, 2015.

KWON, J. et al. Photovoltaic Power Conditioning System With Line Connection. IEEE Transactions on Industrial Electronics, New York, v. 53, n. 5, p. 1048-1054, 2006.

LOPES, R. J. C. Efeito do Sombreamento nos Painéis Fotovoltaicos. Dissertação de Mestrado – Instituto Superior de Engenharia de Lisboa, Lisboa, 2013.

MACKAY, D. J. C. Bayesian interpolation. Neural Computation, 415-447, 1992.

MASOUM, M. A. S; DEHBONEI, H. e FUCHS, E. F. Theoretical and Experimental Analyses of Photovoltaic System With Voltage and Current Based Maximum Power Point Tracking. IEEE Transactions Energy Conversion, vol. 17, pp. 514-522, Dezembro 2002.

MATOS, F. B. Aplicação de Ferramentas de Inteligência Computacional para Estimção das propriedades Físicas de uma Célula Solar de Silício. Tese de doutorado. Universidade Federal de Uberlândia, 2011.

MEDEIROS, T. H.. Treinamento de Redes Neurais Artificiais com Otimização Multi-Objetivo e Regularização Bayesiana: Um Estudo Comparativo. 2004. 124f.

Dissertação (Mestrado) – Universidade Federal do Minas Gerais, Belo Horizonte, 2004

MOCAMBIQUE, N. E. M. Aplicação de Algoritmos de Busca do Ponto de Máxima Potência e controladores lineares e/ou Fuzzy para a regulação da tensão terminal de Painéis Fotovoltaicos. Dissertação de mestrado – Programa de Pós-Graduação em engenharia elétrica, USP, São Carlos, 2012.

OJIMA, D. T. e KOMATSU, W. a MPPT Algorithm Implementation Using FPGA for na Experimental PV System. 9th Brazilian Power Electronics Conference, PP. 672-675, 2008.

OLIVEIRA, T. L.; SILVA, R. C.; GUIMARÃES, G. C.; YAMANAKA, K. Controle de Máxima Potência de um Sistema Fotovoltaico Utilizando Redes Neurais Artificiais. Universidade Federal de Uberlândia, Uberlândia, 2016.

RAUSCHENBACH, H. S. 'Solar Cell Array Design Handbook, Chapter 2. Van Nostrand Reinhold Company, New York 1980.

SEGUEL, L. I. J. Projeto de um sistema fotovoltaico autônomo de suprimento de energia usando técnica MPPT e controle digital, 2009. Dissertação (Mestrado) – Programa de Pós-Graduação em engenharia elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2009.

SÉRA, D. BAGHZOUZ, Y. On the Impacto f Partial Shading on PV Output Power. International Conference on Renewable Energy Sources. Greece. 2008.

SILVA, M.R; ALMEIDA, A.T.; YAMAKAMI, A. Análise de desempenho de redes neurais artificiais para classificação automática de web spam. Revista Brasileira de Computação Aplicada (ISSN 2176-6649), Passo Fundo, v. 4, n. 2, p. 42-57, out. 2012.

SOLARIZE. Sombreamento parcial em arranjos fotovoltaicos. Disponível em: http://www.solarize.com.br/site_content/11-blog/114-sombreamento-parcial-em-arranjos-fotovoltaicos. Acesso em 05 de fev. 2018.

SOLIS, T. M.; CENTENO, T. M. Análise Comparativa de diferentes Funções de Ativação e Número de Camadas de Rede de Leitura de Máquinas de Estado Líquido. XVII Seminário de Iniciação Científica e Tecnológica da UTFPR, 2012.

TEIXEIRA, R. A. Treinamento de Redes Neurais Artificiais Através de Otimização Multi-Objetivo: Uma Nova Abordagem para o Equilíbrio entre a Polarização e a Variância. Tese de doutorado. Escola de Engenharia da UFMG Belo Horizonte, 2001.

TIKHNOV, A. N. & ARSENIN, V. Y.(1977). Solutions of Ill posed Problems, Vh Winston Torgo, L, (1995). Data fitting with rule-based regression.

VERMURU, S.; SINGH, P.; NIAMAT, M. Modeling Impact of Bypass Diodes on Photovoltaic Cell Performance Under Partial Shading. IEEE, International Conference on Electro/Information Technology, May 2012.

VILLALVA, M.G; GAZOLI, J.R; FILHO, E.R. Comprehensive approach to modeling and simulation of photovoltaic arrays. IEEE Transactions on Power Eletronics, 2009, v.24, n.5, p. 1198 – 1208